

# **MODELO PARA LA PREDICCIÓN DE LA RADIACIÓN SOLAR A PARTIR DE REDES NEURONALES ARTIFICIALES**

**ANDRÉS FELIPE GONZÁLEZ RODRÍGUEZ**

**Trabajo de grado para optar al título de  
Ingeniero mecatrónico**

**JUAN ALEJANDRO PEÑA PALACIO (PhD)**



**ESCUELA DE INGENIERÍA DE ANTIOQUIA  
INGENIERIA MECATRÓNICA  
ENVIGADO  
2013**

# **AGRADECIMIENTOS**

Gracias a Dios.

A mi familia, amigos y profesores.

# CONTENIDO

	pág.
INTRODUCCIÓN.....	10
1. PRELIMINARES.....	11
1.1 Planteamiento del problema .....	13
1.2 Objetivos del proyecto.....	13
1.2.1 Objetivo General.....	13
1.2.2 Objetivos Específicos .....	13
1.3 Marco de referencia.....	13
2. METODOLOGÍA.....	17
3. PROCEDIMIENTO .....	19
4. DISCUSIÓN DE RESULTADOS.....	45
5. CONCLUSIONES Y CONSIDERACIONES FINALES .....	46
BIBLIOGRAFÍA.....	47
ANEXO 1.....	50
ANEXO 2.....	64
ANEXO 3.....	70

## LISTA DE TABLAS

	pág.
Tabla 1. Información climática disponible en el punto de medición número 1. Aeropuerto de Darwin en el periodo septiembre a noviembre del 2012.....	20
Tabla 2. Información climática disponible en el punto de medición número 2. Katherine Country Club en el periodo septiembre a noviembre del 2012. ....	21
Tabla 3. Información climática disponible en el punto de medición número 3. Daly Waters AWS en el periodo septiembre a noviembre del 2012.....	22
Tabla 4. Información climática disponible en el punto de medición número 4. Tennant Creek Airport en el periodo septiembre a noviembre del 2012. ....	23
Tabla 5. Información climática disponible en el punto de medición número 5. Territory Grape Farm en el periodo septiembre a noviembre del 2012. ....	24
Tabla 6. Resultados del análisis de correlación entre las demás variables climáticas y la radiación solar en cada centro meteorológico. Los valores mostrados en la tabla son el punto P arrojado por el programa MATLAB. ....	26
Tabla 7. Resultados del análisis de correlación de la radiación solar entre los diferentes puntos de medición. Los valores mostrados en la tabla son el punto P entregados por el programa MATLAB. ....	27
Tabla 8. Datos de entrada correspondientes a cada punto de medición. ....	31
Tabla 9. Tabla de resultados para la prueba de entrenamiento. ....	33
Tabla 10. Tabla de resultados para prueba de aprendizaje y pronóstico. ....	33
Tabla 11. Valor RMSE obtenido por las redes neuronales al variar el número de neuronas en la capa oculta y el alfa en el entrenamiento con información del punto de medición 1. ....	34
Tabla 12. Valor RMSE obtenido por las redes neuronales al variar el número de neuronas en la capa oculta y el alfa en el entrenamiento con información del punto de medición 2. ....	34
Tabla 13. Valor RMSE obtenido por las redes neuronales al variar el número de neuronas en la capa oculta y el alfa en el entrenamiento con información del punto de medición 3. ....	35
Tabla 14. Valor RMSE obtenido por las redes neuronales al variar el número de neuronas en la capa oculta y el alfa en el entrenamiento con información del punto de medición 4. ....	35

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Tabla 15. Valor RMSE obtenido por las redes neuronales al variar el número de neuronas en la capa oculta y el alfa en el entrenamiento con información del punto de medición 5.	35
Tabla 16. Valor RMSE obtenido por las redes neuronales al variar el número de iteraciones y la función de activación en el entrenamiento con información del punto de medición 1.	36
Tabla 17. Valor RMSE obtenido por las redes neuronales al variar el número de iteraciones y la función de activación en el entrenamiento con información del punto de medición 2.	36
Tabla 18. Valor RMSE obtenido por las redes neuronales al variar el número de iteraciones y la función de activación en el entrenamiento con información del punto de medición 3.	37
Tabla 19. Valor RMSE obtenido por las redes neuronales al variar el número de iteraciones y la función de activación en el entrenamiento con información del punto de medición 4.	37
Tabla 20. Valor RMSE obtenido por las redes neuronales al variar el número de iteraciones y la función de activación en el entrenamiento con información del punto de medición 5.	37
Tabla 21. Valor RMSE obtenido por las redes neuronales al variar el número de iteraciones y la función de activación en la predicción con información del punto de medición 1.....	38
Tabla 22. Valor RMSE obtenido por las redes neuronales al variar el número de iteraciones y la función de activación en la predicción con información del punto de medición 2.....	38
Tabla 23. Valor RMSE obtenido por las redes neuronales al variar el número de iteraciones y la función de activación en la predicción con información del punto de medición 3.....	38
Tabla 24. Valor RMSE obtenido por las redes neuronales al variar el número de iteraciones y la función de activación en la predicción con información del punto de medición 4.....	39
Tabla 25. Valor RMSE obtenido por las redes neuronales al variar el número de iteraciones y la función de activación en la predicción con información del punto de medición 5.....	39
Tabla 26. Valor estimado de HSP de las cinco estaciones climáticas con el valor de pronóstico obtenido para los siguientes cinco días. ....	40
Tabla 27. Potencia aproximada que adquieren los vehículos solares durante la carrera el World Solar Challenge. ....	40
Tabla 28. Resultados prueba de Kolmogorov para los valores de radiación del año 2013 en cada punto.....	41

## LISTA DE FIGURAS

	pág.
Figura 1. Incidencia de radiación solar.....	12
Figura 2. Estructura de la neurona.....	14
Figura 3. Estructura de la red multicapa. ....	15
Figura 5. Predicción de un paso del tiempo (Isasi Viñuela & Galván León, 2004).....	16
Figura 6. Mapa de ruta de la competencia World Solar Challenge 2013. (Route Map) ....	19
Figura 7. Ubicación centro de medición climática del aeropuerto de Darwin, estación 014015 del departamento de meteorología del gobierno australiano.....	21
Figura 8. Distancia entre el centro de medición climática Katherine Country Club (B) y el punto de control del WSC número 1 (A). ....	22
Figura 9. Distancia entre el centro de medición climática Daly Waters AWS (B) y el punto de control del WSC número 2 (A). ....	23
Figura 10. Distancia entre el centro de medición climática Tennant Creek Airport (B) y el punto de control del WSC número 3 (A). ....	24
Figura 11. Distancia entre el centro de medición climática Territory Grape Farm (B) y el punto de control del WSC número 4 (A). ....	25
Figura 12. Diagramas de autocorrelación de los datos de radiación solar tomados de: a) aeropuerto de Darwin, b) Katherine Country Club, c) Daly Waters AWS, d) aeropuerto de Tennant Creek, e) Territory Grape Farm. Obtenidos mediante MATLAB. ....	29
Figura 13. Estructura de la red neuronal para predecir puntos intermedios entre las localidades.....	41
Figura 14. Variación de la estructura para predecir puntos intermedios entre las localidades. ....	43
Figura 15. Mapa de radiación solar generado por la red neuronal base radial. ....	43
Figura 15. Grafica 3D de la predicción de los valores de radiación.....	44

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

## LISTA DE ANEXOS

pág.

<a href="#">ANEXO 1</a> .....	¡ERROR! MARCADOR NO DEFINIDO.
<a href="#">ANEXO 2</a> .....	¡ERROR! MARCADOR NO DEFINIDO.
<a href="#">ANEXO 3</a> .....	¡ERROR! MARCADOR NO DEFINIDO.

## **RESUMEN**

La estimación de los cambios climáticos que ocurren en un lugar determinado siempre ha sido un factor importante a la hora de realizar actividades al aire libre. Se han desarrollado diversos métodos para predecir los valores futuros de las variables climáticas, los cuales permiten brindar información a personas y empresas para que puedan organizar sus actividades. La radiación solar hace parte de estas variables climáticas y se ha convertido en información vital en múltiples circunstancias, destacándose su uso en centrales fotovoltaicas. El objetivo de este trabajo es predecir de manera aproximada el valor de radiación solar que incide sobre los vehículos solares que compiten en el World Solar Challenge 2013 en cinco localidades cercanas a la carretera donde se lleva a cabo la competencia, para esto se analiza y desarrolla un modelo basado en redes neuronales. Además se busca conocer el valor de la radiación solar incidente sobre puntos intermedios a los cinco mencionados anteriormente, mediante la utilización de funciones radiales espaciales.

Palabras clave: Redes neuronales, radiación solar, energía renovable, celdas fotovoltaicas, World Solar Challenge.



## **ABSTRACT**

The estimation of the climatic change that occurs in a particular place has always been an important factor for doing outdoor activities. Different methods have been developed to predict future values of climatic variables which can provide information to people and companies, allowing them to organize their activities. The solar radiation is one of these climatic variables and it has become fundamental in multiple circumstances, especially in photovoltaic centers. The project's goal is to give an approximated value of the solar radiation that impacts the solar vehicles of the World Solar Challenge 2013 in five locations close to the road where the competition occurs; for this to be carried out, a model based in neural networks is analyzed and developed. It also seeks to find the value of the solar radiation at intermediate points of the five mentioned before using space radial functions.

Key words: Neural networks, solar radiation, renewable energy, photovoltaic cells, World Solar Challenge.

## INTRODUCCIÓN

El conocer los cambios climáticos en determinado lugar siempre ha sido un factor importante para realizar cualquier actividad al aire libre, tanto para empresas que requieran que sus labores se realicen en exteriores, como para las personas que disfrutan realizar actividades en lugares descubiertos. Por tales motivos se han desarrollado diversos métodos para predecir los valores futuros de las variables climáticas, permitiéndole a las empresas y personas generar un cronograma de actividades a partir de esta información.

Para lograr conocer estas variaciones climáticas se han desarrollado diversas metodologías las cuales incluyen el uso de métodos matemáticos y computacionales, entre los que se destacan los modelos de redes neuronales artificiales. En investigaciones como las llevadas a cabo por Gustavo Ovando *et Al.* (2011) se desarrollaron redes neuronales artificiales capaces de realizar la estimación de la radiación solar horaria en la provincia de Córdoba, Argentina utilizando variables meteorológicas de sencilla adquisición. De manera similar Zeng *et Al.* (2011) proponen un modelo para el pronóstico de la radiación solar en un periodo de tiempo corto por medio del uso de una red neuronal base radial, mientras que Khatib *et Al.* (2012) proponen un método de predicción de la energía solar usando una red neuronal artificial feedforward del tipo perceptrón multicapa.

En este caso el objetivo del trabajo es predecir de manera aproximada el valor de radiación solar que incide sobre los vehículos solares que se encuentran compitiendo en el World Solar Challenge 2013; para satisfacer este objetivo se desarrolla y analiza un modelo basado en redes neuronales para la predicción de la radiación solar de los próximos cinco días a partir del último dato empleado para el aprendizaje y tomado en cinco localidades diferentes de Australia. A su vez, se busca conocer el valor de la radiación solar incidente sobre puntos intermedios a los cinco mencionados anteriormente, mediante la utilización de funciones radiales espaciales. Para el desarrollo de este modelo se plantea una metodología de análisis de datos, pasando por etapas como el diseño del modelo, su desarrollo y validación.

# 1. PRELIMINARES

Desde hace muchos años se ha tratado de conocer la forma de predecir acontecimientos futuros de manera que se puedan tomar acciones preventivas. Dentro de estos eventos futuros se encuentran las condiciones climáticas, las cuales nos afectan directa o indirectamente todos los días. Por ello se han desarrollado métodos de predicción del clima apoyados en las redes neuronales artificiales y otros métodos numéricos.

Uno de estos métodos apoyados en las redes neuronales artificiales consistió en el uso de estas para modelar la predicción de heladas, fue desarrollada por Gustavo Ovando, Monica Bocco y Silvina Savago y se basó en redes neuronales tipo Backpropagation, para su desarrollo se utilizaron datos meteorológicos de un periodo de tiempo de 24 años. Tomando los primeros 10 años como conjunto de entrenamiento de las redes neuronales y los 14 restantes como validación del aprendizaje de la red neuronal, durante su desarrollo se tuvieron en cuenta otros tipos de datos meteorológicos como lo son la temperatura, humedad relativa, nubosidad, entre otros (Ovando, Bocco, & Sayago, 2005).

Otro estudio realizado para el pronóstico del clima a partir de redes neuronales fue la predicción de la temperatura mínima en condiciones de viento en calma y cielo despejado, tomando como base para la predicción la temperatura y el punto de rocío. Este proyecto se realizó entrenando las redes neuronales con información climática de los últimos 8 años tomada de la estación de Tunuyán en Argentina. Dentro del documento de este estudio se indica el desarrollo de redes neuronales para la predicción de la radiación solar a partir de las temperaturas máxima y mínima, precipitaciones y otras variables (Bustos, 2012).

En el mundo se han desarrollado diferentes modelos para predecir la radiación solar a partir del uso de ecuaciones matemáticas o redes neuronales. Uno de estos se realizó para conocer la radiación solar media mensual en África, utilizando una red neuronal multicapa con un algoritmo Backpropagation (Sayago, Bocco, Ovando, & Willington, 2011). De forma similar se han utilizado redes neuronales artificiales de tipo Backpropagation, capaces de predecir la radiación solar diaria a partir de datos meteorológicos, por medio del análisis del comportamiento de las redes al eliminar datos de entrada (Bocco, Ovando, & Sayago).

En la Universidad Nacional de Córdoba (UNC) se diseñó un sistema de redes neuronales capaz de pronosticar la incidencia del sol en posibles zonas de siembra. Esta predicción se logró a partir del estudio de imágenes satelitales (UNC, 2006).

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



**Figura 1. Incidencia de radiación solar<sup>1</sup>**

Anteriormente se han realizado programas utilizando redes neuronales para predecir de manera aproximada el comportamiento de diferentes factores climáticos como el realizado por el grupo de investigación de la universidad de las palmas de gran canaria (ULPGC), cuya finalidad es encontrar lugares óptimos para la construcción de plantas fotovoltaicas (FV) y termo solares, este tipo de modelos toma información del terreno en el cual se quieren construir dichas plantas, logrando obtener modelos del cielo sin nubes para posteriormente analizarlos como cielo real (admin\_ulpgc, 2012).

En estudios de pronóstico de potencia solar anteriores utilizando redes neuronales artificiales se optó por realizar las pruebas haciendo uso de una función base radial con una representación en 2D de la radiación solar y otras variables meteorológicas como variables de entrada (Zeng & Qiao, 2011). En Malasia se desarrolló un metodo de predicción de la energia solar utilizando redes neuronales artificiales con cuatro entradas y una salida. Las entradas utilizadas fueron latitud, longitud, proporcion de luz solar y el número de día. Durante la investigación se utilizó la información de 28 estaciones climaticas, de las cuales 23 estaciones fueron utilizadas para el entrenamiento y 5 como validación (Khatib, Mohamed, Sopian, & Mahmoud, 2012).

---

<sup>1</sup> Recuperado de: <http://2.bp.blogspot.com/-Xsd-bEXFwSs/UJAzc3FLxJI/AAAAAAAAIDc/Hn0I7yJlcqU/s1600/EFEECTO+INVERNADERO.gif>

## **1.1 PLANTEAMIENTO DEL PROBLEMA**

¿Es posible conocer la potencia total adquirida por las celdas fotovoltaicas de un vehículo solar a partir de la predicción de la radiación solar en ciertas localidades de Australia por medio del entrenamiento de redes neuronales artificiales?

## **1.2 OBJETIVOS DEL PROYECTO**

### **1.2.1 Objetivo General**

Desarrollar un modelo basado en redes neuronales capaz de predecir el valor de la radiación solar de los próximos cinco (5) días a partir del último dato empleado para el aprendizaje y tomado en cinco (5) localidades diferentes de Australia, de forma que sea posible calcular un valor aproximado de la potencia total adquirida por las celdas fotovoltaicas de los vehículos solares que compiten en el World Solar Challenge en dichas localidades.

### **1.2.2 Objetivos Específicos**

- Analizar el comportamiento de las series de tiempo que determinan el valor de la radiación solar en cinco (5) localidades de Australia.
- Diseñar el modelo propuesto mediante la utilización de los principios de la inteligencia computacional y las redes neuronales así como de funciones de activación convenientes para este tipo de modelos.
- Desarrollar el modelo teniendo en cuenta para ello algunos estudios con redes neuronales diseñados anteriormente.
- Validar el modelo para los valores de radiación medidos en las localidades descritas anteriormente y calcular la potencia total aproximada adquirida por celdas fotovoltaicas.

## **1.3 MARCO DE REFERENCIA**


Es posible llegar a predecir la potencia del sol mediante modelos físicos y estadísticos, siendo estos primeros los que se basan en sucesos de la atmósfera que afectan la radiación solar, este tipo de modelos son utilizados para estimar con una alta resolución la radiación directa y difusa. Por otro lado los modelos estadísticos de predicción se basan en el análisis de series de tiempo, siendo bastante útiles en predicción a corto plazo. Usualmente se utilizan métodos lineales para la predicción de la potencia solar como lo son el autoregresivo y autoregresivo de media móvil, métodos no lineales como el Takagi-Sugeno y en algunas ocasiones las redes neuronales artificiales. Algunos estudios indican que las redes neuronales artificiales poseen un buen desempeño con este tipo de modelos. A su

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

vez el poseer diversas variables como la temperatura y la velocidad del viento significan una mejora para la predicción con redes neuronales artificiales (Zeng & Qiao, 2011).

En el 2004 Pedro Isasi Viñuela e Inés M. Galván León definen el objetivo de las redes neuronales artificiales como el llegar a diseñar maquinas con elementos neuronales de procesamiento paralelo, de forma que estos puedan “emular” los sistemas neuronales animales.

El funcionamiento interno de las redes neuronales artificiales simuladas por computadoras se da de la siguiente manera: se les proporciona información de entrada y esta se compara con una salida deseada para realizar su entrenamiento, disminuyendo su error de forma progresiva. Las neuronas artificiales son elementos con un estado interno (nivel de activación) que cambia dependiendo de las señales que recibe, este tipo de neuronas también poseen una función de transición la cual les permite cambiar el nivel de activación con las señales recibidas desde neuronas a las que estén conectadas o desde el exterior (Isasi Viñuela & Galván León, 2004).

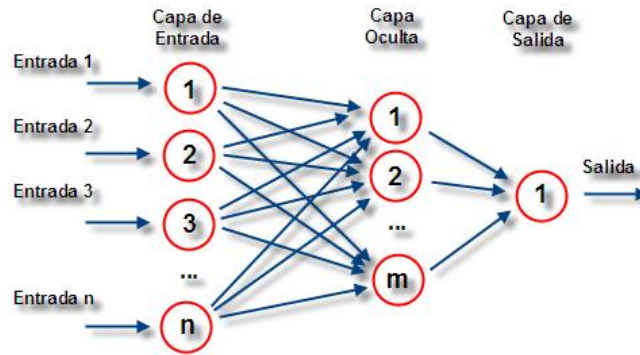


**Figura 2. Estructura de la neurona<sup>2</sup>.**

La forma en que se conectan las neuronas es conocida como patrón de conectividad o arquitectura de la red. Las redes neuronales poseen una estructura básica que consiste en una serie de entradas que llegan a la neurona y una o varias salidas que se encuentran conectadas a la entrada de otra neurona de la red, a esta estructura se le conoce como red multicapa y se representa como se muestra en la figura 3. Este tipo de estructura posee una serie de neuronas en la capa de entrada encargadas de recibir las señales del exterior; posteriormente se encuentra una capa intermedia que recibe el nombre de capa oculta, la cual posee neuronas encargadas de responder a rasgos particulares que puedan ocurrir en los patrones de entrada, el número de estas capas puede variar. Por último se ubica la capa de salida que sirve como salida de toda la red (Isasi Viñuela & Galván León, 2004).

---

<sup>2</sup> Recuperado de: <http://proton.ucting.udg.mx/posgrado/cursos/idc/neuronales2/Fig132.gif>.



**Figura 3. Estructura de la red multicapa<sup>3</sup>.**

Ya que las redes neuronales son capaces de aprender a partir de los datos de entrada y salida conocidos de un sistema se puede llegar a conocer un valor futuro. El conocimiento de este valor se puede realizar en un paso de tiempo, el cual se obtiene a partir de unas muestras disponibles en un instante  $t$  y genera un valor para el instante  $t+1$ . También es posible predecir en múltiples pasos de tiempo, lo cual consiste en tomar los demás valores de la predicción como valores conocidos para generar otros nuevos (Isasi Viñuela & Galván León, 2004).

Para el entrenamiento de las redes neuronales es necesario hacer uso de las siguientes ecuaciones:

$$a_i^1 = x_i \text{ para } i = 1, 2, \dots, n_1 \quad (1)$$

**Ecuación 1. Activación de la capa de entrada ( $a_i^1$ ) (Isasi Viñuela & Galván León, 2004).**

La ecuación 1 corresponde a la activación de la capa de entrada ( $a_i^1$ ). Las neuronas de la capa de entrada transmiten las señales recibidas del exterior hacia la red, donde la expresión  $X = (x_1, x_2, \dots, x_{n_1})$  representa los patrones de entrada a la red.

$$a_i^c = f\left(\sum_{j=1}^{n_{c-1}} w_{ji}^{c-1} a_j^{c-1} + u_i^c\right) \text{ para } i = 1, 2, \dots, n_c \text{ y } c = 2, 3, \dots, c-1 \quad (2)$$

**Ecuación 2. Activación de las neuronas en la capa oculta (Isasi Viñuela & Galván León, 2004).**

---

<sup>3</sup>Recuperado de:

<http://upload.wikimedia.org/wikipedia/commons/6/64/RedNeuronalArtificial.png>.

Se hace uso de la ecuación 2 para activar de las neuronas de la capa oculta. El termino  $w$  corresponde a los pesos de las neuronas ocultas y  $u$  corresponde a los umbrales de las neuronas (Isasi Viñuela & Galván León, 2004).

$$y_i = a_i^c = f \left( \sum_{j=1}^{n_{c-1}} w_{ji}^{c-1} a_j^{c-1} + u_i^c \right) \text{ para } i = 1, 2, \dots, n_c \quad (3)$$

**Ecuación 3. Activación de las neuronas de la capa de salida (Isasi Viñuela & Galván León, 2004).**

Finalmente se procede a activar las neuronas de la capa de salida por medio de la ecuación 3 y la expresión  $Y = (y_1, y_2, \dots, y_{n_c})$  representa el vector de salida de la red. (Isasi Viñuela & Galván León, 2004).

Existen varios algoritmos que le permiten a las redes neuronales corregir el error de la salida, el “backpropagaton” es uno de los más utilizados, este propaga el error desde la capa de salida hacia atrás hasta llegar a la de entrada, permitiéndole a los pesos de la red adaptarse y corregir el error (Ovando, Bocco, & Sayago, 2005)


Para el entrenamiento de la red se hace necesario el uso del método de descenso del gradiente estocástico, definido por Isasi *et Al.* como

$$w(n) = w(n-1) - \alpha \frac{\partial e(n)}{\partial w} \quad (4)$$

**Ecuación 4. Método de descenso del gradiente estocástico (Isasi Viñuela & Galván León, 2004).**

Donde  $w(n)$  corresponde a los valores de los pesos de las neuronas en el tiempo  $n$  y  $\alpha$  corresponde al valor que multiplica la derivada del error.

En la siguiente figura se muestra un diagrama con las entradas y salidas de una red neuronal para predicción, en donde se ingresan valores de entrada  $x(t)$  hasta  $x(t-r)$  para conseguir un valor futuro en el tiempo  $\hat{x}(t+1)$ .



**Figura 4. Predicción de un paso del tiempo (Isasi Viñuela & Galván León, 2004)**



## 2. METODOLOGÍA

Para el cumplimiento del objetivo del proyecto se definió la siguiente metodología, la cual parte del análisis de estudios realizados previamente y pasa luego al diseño, desarrollo y validación de los modelos.

### **Análisis:**

- Se realizan búsquedas de información relacionada con la radiación solar en cinco localidades de Australia cercanas a la carretera donde se realizará el evento World Solar Challenge 2013. La búsqueda se realiza dentro de bases de datos como la NOAA (National Oceanic and Atmospheric Administration), bases de datos de la NASA Surface Meteorology and Solar Energy, el departamento de meteorología del gobierno australiano (Australian Government Bureau of Meteorology), entre otras fuentes de información. A partir de los hallazgos se define la fuente de información para crear la base de datos y se analiza el comportamiento de las series de tiempo que determinan el valor de la radiación solar.
- Se profundiza acerca del tema, investigando artículos sobre estudios realizados anteriormente relacionados con predicción de condiciones climáticas a partir de la implementación de redes neuronales artificiales y de variables necesarias para el entrenamiento de la red.

### **Diseño:**

- Se determina el número de datos para el entrenamiento de la red y otras variables climáticas útiles como temperatura máxima y mínima y horas de sol durante el día a partir de los análisis realizados previamente.
- Se elabora la base de datos que contendrá las entradas de la red neuronal para la predicción de la radiación solar, incluyendo las variables climáticas que se encuentren relacionadas con la radiación.
- Se diseña un modelo de predicción mediante el uso de los principios de la inteligencia computacional y se seleccionan funciones de activación comúnmente utilizadas en estos. Se determina el tipo de modelo a desarrollar, el cual consiste en una red neuronal MADALINE y una perceptrón multicapa para el aprendizaje de las variables climáticas y la predicción de la radiación solar en cada uno de los puntos, además se evalúa la posibilidad del uso de una red neuronal base radial para la aproximación de valores de radiación en puntos intermedios.

### **Desarrollo:**

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

- Se desarrollan los modelos MADALINE y perceptrón multicapa con las funciones de activación seleccionadas en el diseño. De igual forma se desarrolla el modelo base radial encargado de la estimación de puntos intermedios entre los puntos de predicción seleccionados.
- Se implementan las funciones de activación seleccionadas a partir de los estudios realizados.

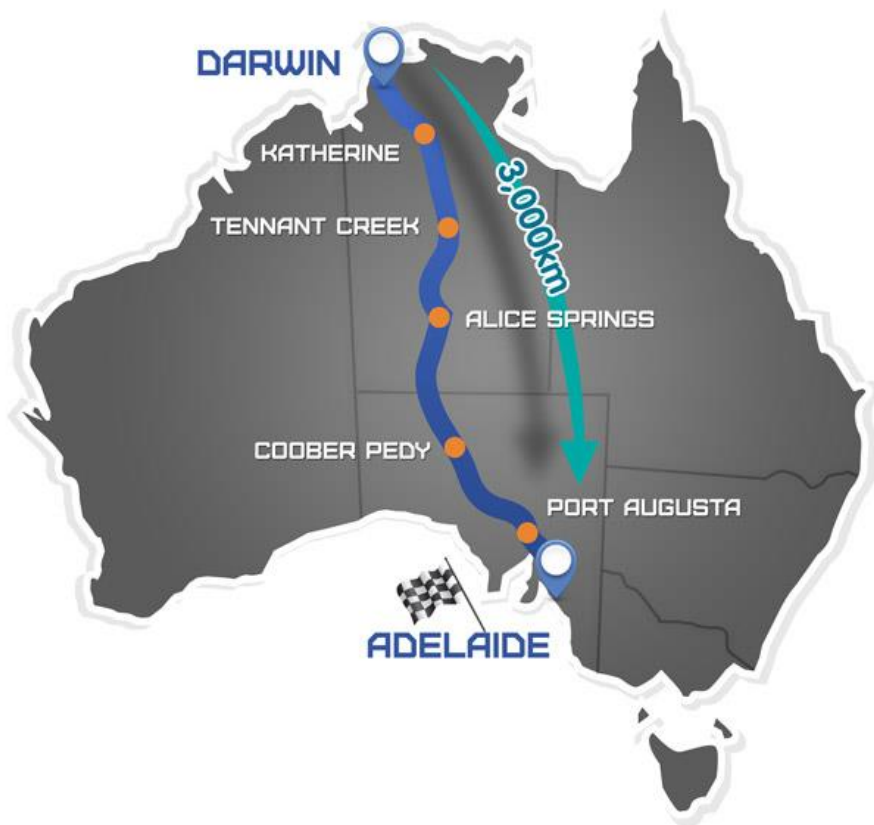
**Validación:**

- Se realizan pruebas para la determinación de parámetros necesarios para el entrenamiento y predicción de las redes neuronales artificiales.
- Se comparan las funciones de activación implementadas en el modelo, buscando determinar si el hecho de incluirlas en este significa una mejora durante el entrenamiento y predicción.
- Por último se validan los modelos de predicción desarrollados comparando la salida de la red con valores de radiación solar conocidos, a su vez se comparan los valores de predicción entregados al hacer uso de las funciones de activación. Para la validación de la red neuronal base radial se genera un mapa con los valores calculados por esta, determinando los valores futuros de radiación en puntos intermedios a los seleccionados.

### 3. PROCEDIMIENTO

Para el cumplimiento de los objetivos del proyecto se parte de la metodología descrita anteriormente. Comenzando con la búsqueda de centros meteorológicos cercanos a la carretera donde se realizará el evento World Solar Challenge 2013.

La página oficial del evento indica que la carrera comienza desde la ciudad de Darwin y llega hasta la ciudad de Port Augusta a través de la carretera Stuart Highway; durante este recorrido los vehículos solares deben llegar a otras localidades como lo son Katherine, Tennant Creek, Alice Springs y Coober Pedy. Posteriormente los vehículos deben dirigirse desde Port Augusta hasta Adelaide por la vía Highway 1, para culminar allí la competencia. (Route Map)



**Figura 5. Mapa de ruta de la competencia World Solar Challenge 2013. (Route Map)**

Por otro lado se halla información acerca de otras localidades llamadas puntos de control, en las cuales los vehículos deben realizar una parada corta de 30 minutos para que los

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

funcionarios de la carrera observen cualquier anomalía, estos puntos de control se encuentran igualmente cerca de la carretera Stuart Highway, lo que resulta conveniente para la selección de datos. (World Solar Challenge – Control Point 2)

Otras consideraciones que son tomadas en cuenta para la selección de los centros de medición son:

- Que estos se encuentren cerca de los puntos de control utilizados en la competencia en años anteriores para el mismo evento y de las carreteras donde se realiza la competencia de vehículos solares.
- Que el centro meteorológico seleccionado para la obtención de los datos posea suficiente información sobre las otras variables climáticas a analizar (temperaturas máxima y mínima, precipitaciones, entre otras).
- Que la información de radiación solar obtenida del centro meteorológico se encuentre completa, de forma que se asegure la continuidad de la serie de tiempo para la predicción.

Teniendo en cuenta las consideraciones anteriores, se definen los centros meteorológicos así:

- Aeropuerto de Darwin.

La estación meteorológica del aeropuerto de Darwin, proporciona la siguiente información climática:

Información diaria:

Dato	S.E.	R.F.	Ma.T.	Mi.T.	S.H.	M.W.	Cl.9am	Cl.3pm
Completa								
Incompl								
Sin Dato								

**Tabla 1. Información climática disponible en el punto de medición número 1. Aeropuerto de Darwin en el periodo septiembre a noviembre del 2012.**

Siendo:

S.E.	Radiación solar (KW/h).	S.H.	Horas de sol.
R.F.	Precipitaciones (mm).	M.W.	Velocidad máxima del viento (Km/h).
Ma.T.	Temperatura máxima (°C).	Cl.	Nubosidad.
Mi.T.	Temperatura mínima (°C).		

Información complementaria de la estación climática:

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Estación numero: 014015 del departamento de meteorología del gobierno australiano.

Coordenadas: Latitud: 12.42°S, Longitud: 130.89°E.

Elevación: 30 metros.



**Figura 6. Ubicación centro de medición climática del aeropuerto de Darwin, estación 014015 del departamento de meteorología del gobierno australiano<sup>4</sup>.**

- La estación meteorológica de Katherine Country Club, proporciona la siguiente información climática:

Información diaria:

Dato	S.E.	R.F.	Ma.T.	Mi.T.	S.H.	M.W.	Cl.9	Cl.3
Completa								
Incompleta								
Sin Datos								

**Tabla 2. Información climática disponible en el punto de medición número 2. Katherine Country Club en el periodo septiembre a noviembre del 2012.**

Información complementaria de la estación climática:

Estación numero: 014305 del departamento de meteorología del gobierno australiano.

Coordenadas: Latitud: 14.47°S, Longitud: 132.26°E.

<sup>4</sup> Recuperado de: <https://www.google.es/maps/preview#!q=-12.42%2C+130.89&data=!4m15!2m14!1m13!1s0x2cc094058c99a00b%3A0x6471693241573c52!3m8!1m3!1d18869187!2d130.89!3d12.42!3m2!1i1206!2i908!4f13.1!4m2!3d-12.42!4d130.89>.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Elevación: 160 metros.



**Figura 7. Distancia entre el centro de medición climática Katherine Country Club (B) y el punto de control del WSC número 1 (A)<sup>5</sup>.**

El punto de control numero 1 tiene las siguientes coordenadas 14°28'10"S 132°16'33"E y se encuentra ubicado en Katherine.

- La estación meteorológica de Daly Waters AWS, proporciona la siguiente información climática:

Información diaria:

Dato	S.E.	R.F.	Ma.T.	Mi.T.	S.H.	M.W.	Cl.9	Cl.3
Completa								
Incompleta								
Sin Datos								

**Tabla 3. Información climática disponible en el punto de medición número 3. Daly Waters AWS en el periodo septiembre a noviembre del 2012.**

Información complementaria de la estación climática:

<sup>5</sup> Recuperado de:

<https://www.google.es/maps/preview#!data=!4m21!3m20!1m5!1sLOT+3238+Stuart+Hwy%2C+Katherine+East+NT+0850%2C+Australia!2s0x2cbabe5268626d23%3A0x6e465b7e19f4c6b2!3m2!3d-14.467649!4d132.278819!1m4!2s0x2cbabfbc98c87745%3A0xb87d3664f39fef17!3m2!3d-14.4714!4d132.2613m8!1m3!1d9135!2d132.2690931!3d-14.4670364!3m2!1i1206!2i908!4f13.1&fid=0>

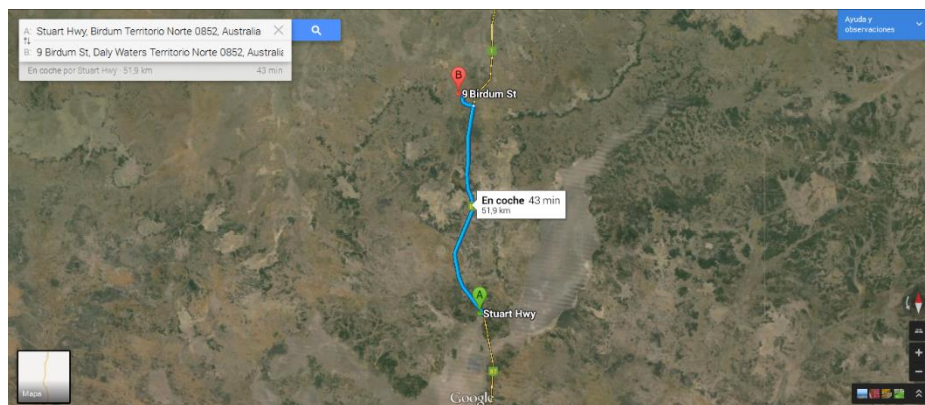
La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



Estación numero: 014626 del departamento de meteorología del gobierno australiano.

Coordenadas: Latitud: 16.26°S, Longitud: 133.38°E.

Elevación: 210 metros.



**Figura 8. Distancia entre el centro de medición climática Daly Waters AWS (B) y el punto de control del WSC número 2 (A)<sup>6</sup>.**

El punto de control numero 2 tiene las siguientes coordenadas 16°40'46"S 133°24'45"E.

- La estación meteorológica de Tennant Creek Airport, proporciona la siguiente información climática:

Información diaria:

Dato	S.E.	R.F.	Ma.T.	Mi.T.	S.H.	M.W.	Cl.9	Cl.3
Completa								
Incompleta								
Sin Datos								

**Tabla 4. Información climática disponible en el punto de medición número 4. Tennant Creek Airport en el periodo septiembre a noviembre del 2012.**

Información complementaria de la estación climática:

<sup>6</sup> Recuperado de: <https://www.google.es/maps/preview#!data=!4m18!3m17!1m1!1s-16.679444444444446%2C+133.4125!1m5!1s9+Birdum+St%2C+Daly+Waters+NT+0852%2C+Australia!2s0x2ca909d507265bc3%3A0x1618f5f78e649261!3m2!3d-16.254088!4d133.370353!3m8!1m3!1d9135!2d132.2698094!3d-14.4656554!3m2!1i1206!2i908!4f13.1&fid=0>.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Estación numero: 015135 del departamento de meteorología del gobierno australiano.

Coordenadas: Latitud: 19.64°S, Longitud: 134.18°E.

Elevación: 376 metros.



**Figura 9. Distancia entre el centro de medición climática Tennant Creek Airport (B) y el punto de control del WSC número 3 (A)<sup>7</sup>.**

El punto de control numero 3 tiene las siguientes coordenadas 19°39'27"S 134°11'17"E y se encuentra ubicado en Tennant Creek.

- La estación meteorológica de Territory Grape Farm, proporciona la siguiente información climática:

Información diaria:

Dato	S.E.	R.F.	Ma.T.	Mi.T.	S.H.	M.W.	Cl.9	Cl.3
Completa								
Incompleta								
Sin Datos								

**Tabla 5. Información climática disponible en el punto de medición número 5. Territory Grape Farm en el periodo septiembre a noviembre del 2012.**

Información complementaria de la estación climática:

<sup>7</sup> Recuperado de:  
<https://www.google.es/maps/preview#!data=!1m4!1m3!1d8885!2d134.1871376!3d-19.6501674!4m18!3m17!1m1!1s-19.6575%2C+134.18805555555556!1m5!1s25+Irvine+St%2C+Tennant+Creek+NT+0860%2C+Australia!2s0x2b4c4c8966f74435%3A0x61872e3722d4186e!3m2!3d-19.6430491!4d134.1838993!3m8!1m3!1d2294842!2d133.81933!3d-18.1621308!3m2!1i1206!2i908!4f13.1&fid=0>.


La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



Estación numero: 015643 del departamento de meteorología del gobierno australiano.

Coordenadas: Latitud: 22.45°S, Longitud: 133.64°E.

Elevación: 566 metros.



**Figura 10. Distancia entre el centro de medición climática Territory Grape Farm (B) y el punto de control del WSC número 4 (A)<sup>8</sup>.**

El punto de control numero 4 tiene las siguientes coordenadas 21°31'51"S 133°53'19"E.

Posteriormente se continúa con el desarrollo de los objetivos planteados dentro de la metodología, para ello se buscan estudios realizados anteriormente sobre el mismo fenómeno o fenómenos similares que sirvan como base para el diseño del modelo y aporten a la toma de decisiones sobre la red neuronal.

De esta forma se hallan artículos como el descrito por Sayago *et. Al* (2011) el cual trata sobre la estimación de la radiación solar horaria a partir de variables meteorológicas básicas, para desarrollarlo se construyeron seis modelos de tipo perceptrón multicapa con propagación de la información hacia adelante en los cuales se tomaron como datos de entrada la temperatura, humedad relativa, velocidad del viento y lluvia y realizaron análisis estadísticos para determinar a cual distribución estadística ajustaba la radiación solar utilizando el test de Kolmogorov. Además en el artículo de Ovando *et. Al* (2011) se realizaron estudios sobre el uso de redes neuronales para la predicción de heladas por

---

<sup>8</sup> Recuperado de: <https://www.google.es/maps/preview#!data=!4m18!3m17!1m1!1s-21.530833333333334%2C+133.88861111111112!1m5!1sAnmatjere+NT%2C+Australia!2s0x2b3628c340e4b37d%3A0x40217a82a254560!3m2!3d-21.8962092!4d133.5799363!3m8!1m3!1d8885!2d134.1871376!3d-19.6501674!3m2!1i1206!2i908!4f13.1&fid=0>.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

medio del desarrollo de modelos basado en redes de tipo “backpropagation”, partiendo de datos meteorológicos de temperatura, humedad relativa, nubosidad, dirección y velocidad del viento. Dentro del texto de *aplicación de redes neuronales al pronóstico de temperaturas máxima y mínima en la provincia de Mendoza* Carlos Bustos desarrolla tres modelos de tipo “perceptrón multicapa” con algoritmo de aprendizaje “backpropagation” para la predicción de la temperatura mínima en condiciones de cielo despejado y viento en calma.

En documentos escritos por Jianwu Zeng y Wei Qiao se logra predecir la potencia solar en un tiempo corto por medio de una red neuronal de base radial en el año 2011 (Zeng & Quiao, 2011); Mohamed *et. Al* utilizan una red neuronal de base radial para la predicción de la radiación solar en Al-Madinah, Arabia Saudita, este modelo utiliza datos meteorológicos como los son la temperatura del aire, horas de sol y la humedad relativa (Benghanem & Mellit, 2010).

Habiendo finalizado la etapa de análisis propuesta en la metodología se prosigue con el diseño del modelo, partiendo por la determinación del número de datos a analizar. Para determinar esto es tomada en cuenta la estación del año correspondiente al periodo de realización del World Solar Challenge. La competencia se realiza durante la primavera, del 6 al 13 de octubre por lo que se tomara esta estación del año para la selección de los datos. El periodo de la primavera comienza desde septiembre y finaliza en noviembre (Clima en Australia), por este motivo la serie de datos que se toma para el entrenamiento de la red neuronal comienza desde septiembre y finaliza en noviembre del año 2012. Posteriormente se toman los mismos datos de las variables climáticas pero pertenecientes al año 2013, el primer dato corresponde al primero de septiembre y el último corresponde al 21 de octubre.

A dichos datos de radiación solar se les realizan análisis de correlación con las demás variables climáticas tomadas con el fin de conocer la influencia de las demás variables tomadas en un punto con respecto a la radiación del mismo, la correlación se calcula utilizando el programa MATLAB instalado en los computadores de la EIA.

Los análisis arrojan los siguientes resultados:

	RF	Tma	Tmi	SH	MW	CI9	CI3
Punto 1	0.11	1.98E-09	4.22E-05	1.99E-07	0.3992	0.3818	4.55E-04
Punto 2	0.4295	0.108	0.01	NaN	4.38E-05	0.4084	0.6927
Punto 3	0.022	0.4901	0.0359	NaN	0.3673	NaN	NaN
Punto 4	0.9918	9.96E-04	3.82E-04	1.29E-09	0.689	4.36E-05	0.055
Punto 5	0.8477	2.85E-07	0.0023	NaN	0.9745	NaN	NaN
Var. Relac.	1/5	3/5	5/5	2/2	1/5	1/3	1/3

**Tabla 6. Resultados del análisis de correlación entre las demás variables climáticas y la radiación solar en cada centro meteorológico. Los valores mostrados en la tabla son el punto P arrojado por el programa MATLAB.**

A partir de los resultados de correlación que se muestran en la figura anterior se puede determinar que otras variables climáticas como la temperatura máxima y mínima están estrechamente relacionadas con el valor de radiación debido a que el valor P entregado por MATLAB es menor a 0.05. Por otro lado, variables climáticas como la precipitación,

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

velocidad del viento y nubosidad no presentan gran relación con la radiación en cada punto, por lo que no se tendrán en cuenta como entradas a la red neuronal. Los datos obtenidos de horas de sol de los puntos de medición 1 y 4 presentan relación con el valor de radiación por lo que se tendrán en cuenta durante la elaboración de la base de datos.

También se analiza la correlación existente entre los valores de todas las variables climáticas con la radiación solar de los diferentes puntos de medición, para determinar si es posible usar las variables climáticas de otros puntos de medición como entradas a la red neuronal.

Correlaciones	RP1	TMaP1	TMiP1	SHP1	RP2	TMaP2	TMiP2	RP3
RP1	0	1.98E-09	4.22E-05	1.99E-07	1.96E-10	0.0567	0.3357	3.84E-07
RP2	1.96E-10	0.0081	1.75E-05	0.4486	0	0.108	0.01	1.18E-15
RP3	3.84E-07	0.0686	1.07E-06	0.8441	1.18E-15	0.0332	0.0181	0
RP4	0.0073	0.8785	1.05E-05	0.0336	5.73E-07	0.8564	0.0055	4.62E-11
RP5	0.0102	0.5954	3.29E-07	0.0063	1.87E-05	0.8025	0.0248	7.27E-09
TMaP3	TMiP3	RP4	TMaP4	TMiP4	SHP4	RP5	TMaP5	TMiP5
0.6348	0.1665	0.0073	0.093	2.81E-05	0.447	0.0102	0.0018	4.48E-05
0.494	0.1113	5.73E-07	0.0229	2.33E-05	0.3244	1.87E-05	3.76E-04	5.29E-05
0.4901	0.0359	4.62E-11	0.0015	1.79E-06	0.0035	7.27E-09	7.13E-06	1.11E-04
0.317	0.0047	0	9.96E-04	3.82E-04	1.29E-09	4.98E-18	8.64E-07	0.0028
0.147	1.27E-04	4.98E-18	0.008	9.32E-04	6.79E-04	0	2.85E-07	0.0023

**Tabla 7. Resultados del análisis de correlación de la radiación solar entre los diferentes puntos de medición. Los valores mostrados en la tabla son el punto P entregados por el programa MATLAB.**

Otro cálculo realizado para la determinación de cantidad de datos a utilizar dentro de la programación es la autocorrelación de la radiación solar en cada uno de los centros meteorológicos seleccionados, lo que permite identificar si los datos existentes son adecuados para ser introducidos al programa y si existen patrones dentro de estos.

La autocorrelación se define como la correlación existente entre los miembros de una serie de observaciones ordenadas en el tiempo o en el espacio (Ordones), también se puede definir como la relación que se da entre variables perturbadoras, que contraviene en uno de los supuestos para estimar el modelo a partir de la independencia que debería existir entre variables (Quispe). Por otro lado la correlación se define como la teoría que busca estudiar la relación o dependencia que existe entre dos variables que intervienen en una distribución bidimensional (Cabaño, 2010).


$$r = \frac{S_{xy}}{S_x S_y} \quad (5)$$

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.


### Ecuación 5. Correlación. (Cabaño, 2010)

Donde  $r$  corresponde la correlación entre las variables  $x$  e  $y$ ,  $S$  corresponde a la varianza de cada variable y  $S_{xy}$  corresponde a la covarianza de estas dos variables.


Los resultados obtenidos son los siguientes:




a)



b)




c)



d)

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



e)

**Figura 11. Diagramas de autocorrelación de los datos de radiación solar tomados de: a) aeropuerto de Darwin, b) Katherine Country Club, c) Daly Waters AWS, d) aeropuerto de Tennant Creek, e) Territory Grape Farm. Obtenidos mediante MATLAB.**

Al terminar de analizar los datos se realiza la selección para utilizar dentro del desarrollo del modelo, los datos seleccionados se encuentran en el Anexo 2.

Las funciones de activación que se introducirán al modelo serán determinadas a partir de las selecciones realizadas por otros autores dentro de sus proyectos como la tangente hiperbólica, lineal, escalón y sigmoidea (Bocco, Ovando, & Sayago) (Bustos, 2012) (Sayago, Bocco, Ovando, & Willington, 2011), aunque algunas funciones como la logística sigmoidea son recomendadas para problemas de predicción (Llano, Hoyos, Arias, & Velásquez, 2007), esto debido a que el empleo de estas puede influir en el desempeño del entrenamiento de la red neuronal (Llano, Hoyos, Arias, & Velásquez, 2007).. Para el modelo a desarrollar se excluye la función de activación de paso ya que la salida toma únicamente los valores de 0 o 1 (Collantes, 2001), siendo insuficiente para conocer el valor de radiación solar futuro. Sayago *et. Al* (2011) utiliza la función de activación tangente hiperbólica para predecir la radiación solar horaria desarrollando seis redes de tipo perceptrón multicapa. Ovando *et. Al* define la función de activación escalón como:

$$f(net_{jk}) = (net_{jk}) \quad (6)$$

**Ecuación 6. Ecuación de la función de activación escalón (Sayago, Bocco, Ovando, & Willington, 2011).**

donde j corresponde a la j-ésima neurona oculta y k corresponde a cada neurona de la capa de salida y define la función de activación sigmoidea como:

$$f(net_{jk}) = \frac{1}{1+e^{-net_{jk}}} \quad (7)$$

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

**Ecuación 7. Ecuación de la función de activación sigmoidea (Sayago, Bocco, Ovando, & Willington, 2011).**

Luego de buscar información acerca de las funciones de activación utilizadas en estudios anteriores se determinan cuales serán implementadas en el modelo, se decide que la tangente hiperbólica y la función sigmoidea (logistic sigmoidal) son las más adecuadas para el modelo debido a que son utilizadas principalmente en modelos de predicción (Llano, Hoyos, Arias, & Velásquez, 2007).

Mejía (2004) define la función tangente hiperbólica está definida como:

$$\varphi(u) = \frac{1-e^{-u}}{1+e^{-u}} \quad (8)$$

**Ecuación 8. Ecuación de la función tangente hiperbólica (Mejía, 2004)**

Y la función sigmoidea se expresa como:

$$\varphi(u) = \frac{1}{1+e^{-u}} \quad (9)$$

**Ecuación 9. Ecuación de la función sigmoidea (Mejía, 2004)**

Los valores entregados por la función de activación tangente hiperbólica a la salida de la red neuronal varían entre 0 y 1 y para la función de activación sigmoideal varía entre -1 y 1, por lo cual los datos de entrada a la red son normalizados para escalarlos entre los valores de 0 a 1. Para la normalización de los datos se utiliza la siguiente ecuación

$$tran(x) = \frac{1}{max_x - min_x} (x - min_x) \quad (10)$$

**Ecuación 10. Ecuación para normalización de datos. (Isasi Viñuela & Galván León, 2004).**

A partir de los estudios mencionados anteriormente y la necesidad de conocer los valores futuros de la radiación solar de los próximos cinco días, se determina el tipo de red como una red neuronal de tipo MADALINE y una perceptrón multicapa la cual incluirá las funciones de activación tangente hiperbólica y sigmoideal. Los datos de variables climáticas definidas anteriormente servirán como entradas a la red neuronal y el valor de radiación solar desfasada cinco días servirá como salida deseada, dejando cinco datos en cada entrada los cuales corresponden a las entradas de los cinco días a predecir. Además se consideraran retardos de los valores, debido a que no se posee gran cantidad de entradas a la red necesarias para el correcto aprendizaje de la red neuronal.

Habiendo finalizado la etapa de diseño de la red, se comienza con la programación del modelo de predicción. Para dicho modelo se inicia con la elaboración del código de una red neuronal de tipo MADALINE y una perceptrón multicapa a las cuales se les ingresan los datos climáticos normalizados como entradas de la red neuronal, estos varían dependiendo

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

del punto de medición en el cual se desea conocer el valor futuro, los datos correspondientes a cada modelo se muestran en la siguiente tabla. El modelo perceptrón multicapa incluye además las funciones de activación tangente hiperbólica y sigmoideal para las cuales se calcula la regla delta generalizada de forma que sea posible propagar el error hacia atrás durante el entrenamiento.

	RP1	TMaP1	TMiP1	SHP1	RP2	TMaP2	TMiP2	RP3
Punto 1	X	X	X	X	X			X
Punto 2	X	X	X		X		X	X
Punto 3	X	X			X	X	X	X
Punto 4	X	X		X	X		X	X
Punto 5	X	X		X	X		X	X

	TMiP3	RP4	TMaP4	TMiP4	SHP4	RP5	TMaP5	TMiP5
Punto 1		X	X			X	X	X
Punto 2		X	X	X		X	X	X
Punto 3	X	X	X	X	X	X	X	X
Punto 4	X	X	X	X	X	X	X	X
Punto 5	X	X	X	X	X	X	X	X

**Tabla 8. Datos de entrada correspondientes a cada punto de medición.**

Durante el desarrollo del modelo se realizaron cuatro tipos de redes, dos de tipo MADALINE y las otras dos de tipo perceptrón multicapa. Una de las MADALINE se define únicamente para el entrenamiento de la red neuronal permitiendo obtener los valores de salida de la red y entregando los valores de los pesos de cada neurona perteneciente a la capa oculta y la capa de salida. El otro modelo MADALINE permite que la red neuronal pase por un periodo de entrenamiento y validación, además permite tomar los valores de los pesos de las neuronas de la capa oculta y capa de salida de otras redes neuronales entrenadas previamente. De igual forma se desarrollan los modelos perceptrón multicapa, en el cual uno se define para el entrenamiento de la red y el otro para entrenamiento y validación.

Todos los modelos mencionados necesitan en primera medida conocer el número de datos que se analizarán los cuales corresponden al número de días para entrenamiento, además requieren el número de entradas de la red y la cantidad de veces que el programa realizará el entrenamiento. Luego de obtener esta información el programa toma los valores de entrada y salida deseados que se determinaron previamente y los almacena en una matriz, acto seguido se generan valores aleatorios para los pesos pertenecientes a la capa oculta y capa de salida; en el caso de la MADALINE y perceptrón multicapa para aprendizaje y predicción estas toman los valores de los pesos guardados anteriormente a menos que se defina que generará nuevos pesos aleatoriamente.

Cuando el modelo almacena todos los datos anteriormente mencionados este inicia el proceso de aprendizaje como se menciona en el marco de referencia.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



A continuación se definirá la regla delta generalizada para el modelo perceptrón multicapa que cuenta con función de activación tangente hiperbólica y sigmoideal en la capa de salida, determinando la expresión que permita propagar el error hacia atrás de forma que sea posible generar una disminución en el error. La ecuación 10 corresponde a la función tangente hiperbólica, si se aplica el método del descenso del gradiente estocástico para propagar el error a los pesos de la capa de salida este queda expresado de la siguiente forma.

$$Cj_k = Cj_{k-1} + \alpha * er * \frac{\partial \tanh(CjSj)}{\partial Cj} \quad (11)$$

**Ecuación 11. Regla delta generalizada para la propagación del error a las neuronas de la capa de salida.**

, donde

$$\frac{\partial \tanh(CjSj)}{\partial Cj} = Sj * Sech^2(CjSj) = S * \left( \frac{2}{e^{CjSj} + e^{-CjSj}} \right)^2 \quad (12)$$

**Ecuación 12. Regla delta generalizada para la propagación del error a las neuronas de la capa de salida utilizada en la programación.**

Luego se aplica el método del gradiente del error a las neuronas de la capa oculta a partir de la siguiente expresión

$$Wj_k = Wj_{k-1} + \alpha * er * \frac{\partial \tanh(CjXjiWji)}{\partial Wji} \quad (13)$$

**Ecuación 13. Regla delta generalizada para la propagación del error a las neuronas de la capa oculta.**

Donde

$$\frac{\partial \tanh(CjXjiWji)}{\partial Wji} = CjXji * Sech^2(CjWjiXji) = * \left( \frac{2}{e^{CjWjiXji} + e^{-CjWjiXji}} \right)^2 \quad (14)$$

**Ecuación 14. Regla delta generalizada para la propagación del error a las neuronas de la capa oculta utilizada en la programación.**

Por último se calcula el error en la salida como valor RMSE de la siguiente forma.

$$RMSE = \sqrt{\sum_{i=1}^N \frac{(\varphi_i - \varphi_{iobs})^2}{N}} \quad (15)$$

**Ecuación 15. Ecuación para determinar el valor RMSE (Metodología para la evaluación del modelo de pronóstico meteorológico).**

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



El modelo es programado en Visual Studio 2010 y el código se encuentra en el Anexo 3.

El proceso de validación del modelo de predicción comenzó con el aprendizaje de la red neuronal utilizando los datos históricos que corresponden a los valores de las variables climáticas de cada estación seleccionada durante el periodo de septiembre a noviembre del año 2012 como entradas. A partir de estas se realizaron pruebas para el entrenamiento de las redes neuronales, variando el número de neuronas en la capa oculta y el valor de alfa, obteniendo información suficiente para completar la siguiente tabla.

RP#	# alfa	0.005	0.001	0.0005
# Neur				
50				
100				
150				
200				
250				

**Tabla 9. Tabla de resultados para la prueba de entrenamiento.**

Luego se toman los pesos de la red neuronal con error RMSE más bajo y se introducen a una nueva red neuronal a la cual le ingresan los valores de radiación solar del año 2013, con la finalidad de determinar si existe o no mejoría al entrenar la red con datos de años anteriores. Para esta prueba se diseñó la siguiente tabla de resultados.

P o A	Aprendizaje 2012 + 2013				Aprendizaje 2013		
RP#	F.A.	Normal	Tanh	Sigmoidal	Normal	Tanh	Sigmoidal
#Prueba							
500							
1000							
1500							
2000							

**Tabla 10. Tabla de resultados para prueba de aprendizaje y pronóstico.**

La tabla anterior se utiliza para comparar los valores RMSE entregados por los modelos de predicción y de entrenamiento, al igual que ayuda a determinar si existe mejoría en el pronóstico al realizar un entrenamiento previo o implementando alguna de las funciones de activación seleccionadas.

Para la validación de las redes neuronales se utilizaron las tablas 8 y 9 y se buscó comparar la respuesta de varios tipos de redes neuronales a partir de la variación de sus datos de

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

entrada como los son el número de neuronas ocultas y el alfa de aprendizaje. Las pruebas de aprendizaje se realizaron con la información obtenida el año 2012 y 10.000 iteraciones, las tablas de la 11 a la 13 muestran los valores RMSE obtenidos en cada prueba.

RP1	# alfa	0.005	0.001	0.0005
# Neur				
50		0.061523	0.065525	0.078803
100		0.062092	0.066115	0.080432
150		0.064472	0.066398	0.081579
200		0.068945	0.066652	0.081878
250		0.07943	0.066572	0.082018

**Tabla 11. Valor RMSE obtenido por las redes neuronales al variar el número de neuronas en la capa oculta y el alfa en el entrenamiento con información del punto de medición 1.**

RP2	# alfa	0.005	0.001	0.0005
# Neur				
50		0.030609	0.043988	0.05429
100		0.030676	0.044714	0.055449
150		0.030852	0.045167	0.0564
200		0.031369	0.045226	0.056561
250		0.03202	0.04496	0.056153

**Tabla 12. Valor RMSE obtenido por las redes neuronales al variar el número de neuronas en la capa oculta y el alfa en el entrenamiento con información del punto de medición 2.**

RP3	# alfa	0.005	0.001	0.0005
# Neur				
50		0.023585	0.035333	0.044592
100		0.023807	0.035801	0.045902

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

150		0.024057	0.035709	0.045779
200		0.02432	0.035584	0.045366
250		0.024497	0.035412	0.044912

**Tabla 13. Valor RMSE obtenido por las redes neuronales al variar el número de neuronas en la capa oculta y el alfa en el entrenamiento con información del punto de medición 3.**

RP4	# alfa	0.005	0.001	0.0005
# Neur				
50		0.049917	0.067109	0.078487
100		0.053217	0.067864	0.079445
150		0.070471	0.068013	0.079791
200			0.067967	0.079635
250			0.067658	0.079551

**Tabla 14. Valor RMSE obtenido por las redes neuronales al variar el número de neuronas en la capa oculta y el alfa en el entrenamiento con información del punto de medición 4.**

RP5	# alfa	0.005	0.001	0.0005
# Neur				
50		0.04705	0.065577	0.075225
100		0.048308	0.066387	0.07625
150		0.050634	0.06678	0.076415
200		0.050525	0.066424	0.076308
250			0.066295	0.076031

**Tabla 15. Valor RMSE obtenido por las redes neuronales al variar el número de neuronas en la capa oculta y el alfa en el entrenamiento con información del punto de medición 5.**

Las tablas 12 y 13 muestran espacios grises, representando combinaciones entre número de neuronas en la capa oculta y valor de alfa que causan un sobreaprendizaje en la red neuronal. Además a partir del valor RMSE en las tablas se puede observar que los valores más bajos de error se presentan cuando el número de neuronas es bajo y el alfa de aprendizaje es 0.005. Por otro lado, a medida que se aumenta el número de neuronas

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

ocultas el error tiende a aumentar lentamente, mientras que al disminuir el alfa de aprendizaje el error aumenta notoriamente.

Luego de obtener información sobre el aprendizaje de la red, se continúa con la validación de la predicción. Para lograr esto se realiza otro tipo de estudio con las redes neuronales, en la cual se busca comparar la capacidad de aprendizaje y predicción de la red variando las funciones de activación, número de iteraciones de aprendizaje y pesos de la red. Esta última consiste en hacer que la red neuronal utilice los pesos obtenidos durante los entrenamientos en el 2012 o genere pesos aleatorios para el caso 2013.

Los resultados obtenidos al finalizar las pruebas fueron los siguientes.

- Para el periodo de aprendizaje.

Aprendiz	Aprendizaje 2012 + 2013				Aprendizaje 2013		
RP1	F.A.	Normal	Tanh	Sigmoidal	Normal	Tanh	Sigmoidal
#Prueba							
500		0.055354	0.064304	0.115971	0.08425	0.092757	0.128123
1000		0.031507	0.033513	0.102632	0.051736	0.046598	0.119033
1500		0.022579	0.023928	0.089045	0.037196	0.032557	0.110704
2000		0.017089	0.019027	0.074782	0.028309	0.026611	0.101294

**Tabla 16. Valor RMSE obtenido por las redes neuronales al variar el número de iteraciones y la función de activación en el entrenamiento con información del punto de medición 1.**

	Aprendizaje 2012 + 2013				Aprendizaje 2013		
RP2	F.A.	Normal	Tanh	Sigmoidal	Normal	Tanh	Sigmoidal
#Prueba							
500		0.045662	0.049667	0.13991	0.091187	0.077568	0.178215
1000		0.021465	0.02777	0.100443	0.048308	0.039987	0.157742
1500		0.011478	0.017321	0.075032	0.031431	0.025894	0.125656
2000		0.006585	0.011721	0.060884	0.021037	0.01736	0.093535

**Tabla 17. Valor RMSE obtenido por las redes neuronales al variar el número de iteraciones y la función de activación en el entrenamiento con información del punto de medición 2.**

	Aprendizaje 2012 + 2013				Aprendizaje 2013		
RP3	F.A.	Normal	Tanh	Sigmoidal	Normal	Tanh	Sigmoidal
#Prueba							

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

500		0.022105	0.024925	0.064627	0.056697	0.060995	0.083294
1000		0.014414	0.013888	0.053374	0.02553	0.031715	0.078543
1500		0.010807	0.011141	0.043948	0.01615	0.017642	0.073158
2000		0.008314	0.009349	0.035856	0.012605	0.013228	0.067724

**Tabla 18. Valor RMSE obtenido por las redes neuronales al variar el número de iteraciones y la función de activación en el entrenamiento con información del punto de medición 3.**

	Aprendizaje 2012 + 2013				Aprendizaje 2013		
RP4	F.A.	Normal	Tanh	Sigmoidal	Normal	Tanh	Sigmoidal
#Prueba							
500		0.040653	0.042126	0.103672	0.066917	0.060623	0.214733
1000		0.025016	0.024234	0.074465	0.040845	0.037236	0.140833
1500		0.018556	0.016644	0.057741	0.028032	0.024444	0.100303
2000		0.014335	0.012138	0.047386	0.019736	0.0163	0.07668

**Tabla 19. Valor RMSE obtenido por las redes neuronales al variar el número de iteraciones y la función de activación en el entrenamiento con información del punto de medición 4.**

	Aprendizaje 2012 + 2013				Aprendizaje 2013		
RP5	F.A.	Normal	Tanh	Sigmoidal	Normal	Tanh	Sigmoidal
#Prueba							
500		0.048123	0.036257	0.106427	0.059121	0.048956	0.16255
1000		0.021649	0.021792	0.077697	0.034625	0.029359	0.122352
1500		0.012209	0.014205	0.060725	0.025717	0.023648	0.0909
2000		0.007729	0.009808	0.050748	0.019723	0.019605	0.069722

**Tabla 20. Valor RMSE obtenido por las redes neuronales al variar el número de iteraciones y la función de activación en el entrenamiento con información del punto de medición 5.**

Los valores RMSE de la red neuronal iban disminuyendo cada vez que se realizaba la operación de cálculo y aprendizaje, lo que indica que esta posee una buena capacidad para aprender del comportamiento del clima.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

- Estos fueron los resultados de la comparación de los valores RMSE durante el periodo de predicción.

Pronostico	Aprendizaje 2012 + 2013				Aprendizaje 2013		
RP1	F.A.	Normal	Tanh	Sigmoidal	Normal	Tanh	Sigmoidal
#Prueba							
500		0.3398688	0.1705297	0.1638892	0.1976987	0.1618827	0.1583633
1000		0.3549255	0.1702796	0.1631696	0.2052892	0.1604453	0.1575059
1500		0.3613629	0.1696614	0.1627186	0.2130342	0.161859	0.1573264
2000		0.366407	0.1687628	0.1624085	0.2175559	0.1617946	0.1574026

**Tabla 21. Valor RMSE obtenido por las redes neuronales al variar el número de iteraciones y la función de activación en la predicción con información del punto de medición 1.**

	Aprendizaje 2012 + 2013				Aprendizaje 2013		
RP2	F.A.	Normal	Tanh	Sigmoidal	Normal	Tanh	Sigmoidal
#Prueba							
500		0.248373	0.1236867	0.1536585	0.1823307	0.1428768	0.1472302
1000		0.2431906	0.1162239	0.1402317	0.1951135	0.1301008	0.1492893
1500		0.2441932	0.1153208	0.1283987	0.2049591	0.1273769	0.1466038
2000		0.2457712	0.11577	0.1208061	0.2111999	0.1267499	0.1397366

**Tabla 22. Valor RMSE obtenido por las redes neuronales al variar el número de iteraciones y la función de activación en la predicción con información del punto de medición 2.**

	Aprendizaje 2012 + 2013				Aprendizaje 2013		
RP3	F.A.	Normal	Tanh	Sigmoidal	Normal	Tanh	Sigmoidal
#Prueba							
500		0.3147889	0.2287935	0.2049028	0.2306871	0.2007278	0.1928459
1000		0.311757	0.2305539	0.2047158	0.2391905	0.2029204	0.1929711
1500		0.3100545	0.230719	0.2055377	0.2461595	0.2059771	0.1926076
2000		0.3092394	0.2308698	0.2067762	0.2495797	0.2072748	0.1923458

**Tabla 23. Valor RMSE obtenido por las redes neuronales al variar el número de iteraciones y la función de activación en la predicción con información del punto de medición 3.**

Aprendizaje 2012 + 2013	Aprendizaje 2013
-------------------------	------------------

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

RP4	F.A.	Normal	Tanh	Sigmoidal	Normal	Tanh	Sigmoidal
#Prueba							
500		0.3848129	0.2949297	0.259918	0.2683878	0.2351266	0.2512886
1000		0.3979995	0.299018	0.2750612	0.281711	0.2367612	0.2361662
1500		0.4052929	0.304444	0.2861684	0.2913777	0.2393225	0.2372648
2000		0.409457	0.3085155	0.2933726	0.2994418	0.2441391	0.2452784

**Tabla 24. Valor RMSE obtenido por las redes neuronales al variar el número de iteraciones y la función de activación en la predicción con información del punto de medición 4.**

	Aprendizaje 2012 + 2013				Aprendizaje 2013		
RP5	F.A.	Normal	Tanh	Sigmoidal	Normal	Tanh	Sigmoidal
#Prueba							
500		0.2381193	0.1355792	0.140714	0.1779732	0.1229515	0.1305626
1000		0.2603857	0.139644	0.1429136	0.2005055	0.1277103	0.1311404
1500		0.2687099	0.1434664	0.1484921	0.2080774	0.1292072	0.1324653
2000		0.2717991	0.1464711	0.1554172	0.2122387	0.1311232	0.1406853

**Tabla 25. Valor RMSE obtenido por las redes neuronales al variar el número de iteraciones y la función de activación en la predicción con información del punto de medición 5.**

En este caso los valores mínimos de RMSE registrados no se encuentran en la última fila como ocurría con el error durante el aprendizaje, de forma que las condiciones necesarias de entrada de la red para obtener la predicción de la radiación dependen de cada uno de los puntos de medición. Requiriendo que el cálculo de predicción de las redes se haga de forma independiente, con la finalidad de obtener el error más bajo para cada caso.

Para finalizar los objetivos propuestos se realiza el cálculo de la potencia total aproximada que adquieren los paneles solares de los vehículos que compiten en el World Solar Challenge a partir de la siguiente expresión  $W_p \times HSP = Wh/día$  (Calcular paneles y baterías para instalar energía solar en casa, 2013). En donde  $W_p$  es el valor de vatios pico de los paneles solares, mientras que  $HSP$  corresponde a las horas sol pico, estas se calculan de la siguiente forma.  $HSP = Radiación\ solar\ diaria (Wh/m^2\ dia) / 1000W/m^2$  (INSTALACIONES CONECTADAS A LA RED).

Para la aproximación de los valores de radiación solar en los paneles de los vehículos se hará uso de las características del panel solar HIT de panasonic ya que este fue utilizado por el vehículo solar de Tokai en años anteriores (World Solar Car Challenge). Además se tendrá en cuenta la reglamentación de la competencia World Solar Challenge, en la cual lo

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

vehículos solares no pueden exceder un área máxima de 6m cuadrados de panel solar de silicio (Regulations for the 2013 World Solar Challenge).

En la hoja de datos de las celdas solares HIT se determina que el valor de potencia máximo de un panel HIT de 1.26 metros cuadrados es de 240 W, por lo cual si el vehículo utiliza los 6 metros cuadrados la potencia aproximada de este sería de 1.142kW. Para calcular las HSP se toma como número de horas de sol por día el promedio acumulado del mes de octubre entregado por el departamento de meteorología del gobierno australiano para la estación 014015 en Darwin, este promedio acumulado equivale a 9.3.

Al multiplicar los valores pronosticados de radiación solar por 9.3 horas de sol por día se obtiene la siguiente tabla con los valores HSP, la tabla contiene los pronósticos de los cinco días.

Predicción	RP1	RP2	RP3	RP4	RP5
Día 1	75.69802	85.57638	75.61185	77.50836	77.5501
Día 2	76.52856	85.71106	77.25338	79.26605	78.86847
Día 3	77.92744	42.46094	77.09529	76.92469	63.95425
Día 4	77.84568	57.78081	75.38144	73.4185	79.1007
Día 5	78.52896	85.29242	75.07906	77.69894	79.45095

**Tabla 26. Valor estimado de HSP de las cinco estaciones climáticas con el valor de pronóstico obtenido para los siguientes cinco días.**

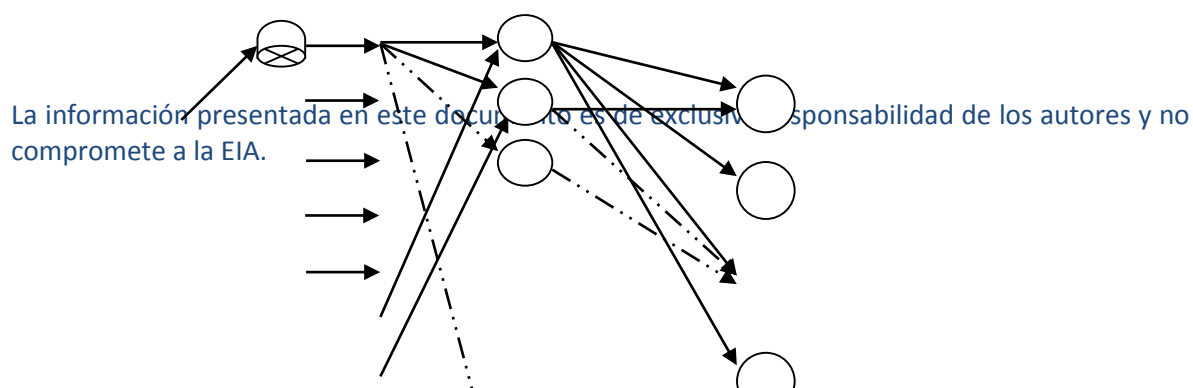
Por lo tanto los valores estimados de potencia adquirida por los paneles por día son los siguientes.

Predicción	RP1	RP2	RP3	RP4	RP5
Día 1	86.44714	97.72822	86.34874	88.51454	88.56221
Día 2	87.39562	97.88203	88.22335	90.52183	90.06779
Día 3	88.99314	48.4904	88.04283	87.848	73.03575
Día 4	88.89977	65.98568	86.08561	83.84393	90.333
Día 5	89.68007	97.40395	85.74028	88.73219	90.73298


**Tabla 27. Potencia aproximada que adquieren los vehículos solares durante la carrera el World Solar Challenge.**

Posteriormente se decide plantear una estructura de red neuronal con el fin de obtener una aproximación de los valores de radiación solar en puntos intermedios entre las localidades donde se recolectaron los datos.

La estructura planteada se muestra a continuación.







**Figura 12. Estructura de la red neuronal para predecir puntos intermedios entre las localidades.**

Para desarrollar esta estructura es necesario definir un área donde se encontraran todos los puntos a aproximar, siendo dicho plano delimitado por los posiciones máxima y mínima de los puntos extremos.

Posteriormente se definen las entradas del modelo como valores de X y Y, los cuales representan puntos entre las centros meteorológicos seleccionados. Luego se determina si los valores de radiación solar de cada uno de los puntos de medición siguen una distribución normal, para ello se realiza la prueba de Kolmogorov (Collantes, 2001). En caso de que la radiación siga una distribución normal se hará uso de la función gaussiana de la red neuronal base radial para estimar el valor de radiación en las demás posiciones.

Los resultados de las pruebas de Kolmogorov se muestran en la siguiente tabla.

	H	P
Punto 1	1	6.90E-25
Punto 2	1	7.62E-25
Punto 3	1	6.95E-25
Punto 4	1	6.92E-25
Punto 5	1	6.42E-24

**Tabla 28. Resultados prueba de Kolmogorov para los valores de radiación del año 2013 en cada punto.**

Al obtener los datos se continúa con la construcción del modelo, para ello se hallan los valores de  $h_x$  y  $h_y$  correspondientes a partir de la siguiente fórmula.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

$$h_x = e^{\left(\frac{-(X_j - X_r)^2}{D_j}\right)} \quad h_y = e^{\left(\frac{-(Y_j - Y_r)^2}{D_j}\right)}$$

a)


b)

**Ecuación 16. Ecuación para hallar los valores de la función gaussiana. a) Para  $h_x$  y b) para  $h_y$ .**

Luego se multiplican las componentes de  $x$  con las componentes  $y$  obteniendo una matriz de los valores calculados por cada uno. Este resultado ingresa a una red neuronal tipo feed forward con la cual se busca obtener los valores de radiación para todos los puntos ingresados, dentro de esta red se multiplican los valores hallados por cada peso para luego ser multiplicados por el valor de radiación de cada punto y obtener un valor de salida para la red.

Posteriormente a la programación del modelo propuesto se realizan pruebas, las cuales arrojan no muy buenos resultados ya que la red neuronal no logra determinar estos valores de radiación, por el contrario afecta los valores que le son ingresados.


Al no obtener los resultados deseados con la implementación de la red neuronal base radial se plantea un nuevo modelo para obtener la aproximación y grafica deseada, definiendo el siguiente modelo.



**Figura 13. Variación de la estructura para predecir puntos intermedios entre las localidades.**

En este modelo se retira la red neuronal base radial y se procede a operar los valores obtenidos por las campanas gaussianas  $h_x$  y  $h_y$  de forma independiente, determinando la cercanía del mapa con respecto a los centros de las funciones gaussianas.

A continuación se muestra una grafica del mapa generado por esta en donde el valor de radiación para todas las entradas es igual a 1.



**Figura 14. Mapa de radiación solar generado por la red neuronal base radial.**


A continuación se muestra una gráfica en tres dimensiones luego de ingresar los valores de radiación solar predichos para el día 1 de cada punto de medición.

Los datos de radiación ingresados son:

$$RP(1) = 0.821383888, \quad RP(2) = 0.98052208, \quad RP(3) = 0.750964868$$

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

$$RP(4) = 0.751678547, \quad RP(5) = 0.809600046$$



**Figura 15. Grafica 3D de la predicción de los valores de radiación.**

Al observar la figura 14 se puede detallar que los valores de radiación solar se afectan por la cercanía del punto al centro de la función, haciendo que se pierda precisión en al momento de calcular la radiación de los puntos que se encuentran por fuera de la función, por este motivo se realiza un nuevo mapa con una cantidad de puntos intermedios menor con la finalidad de obtener datos más cercanos a los entregados por el modelo, dicho mapa corresponde a la figura 15.

## 4. DISCUSIÓN DE RESULTADOS

Dentro de la tabla 6 es posible observar los valores de correlación que existe entre la radiación solar y otras variables climáticas que son medidas en el mismo lugar, dejando claro que se puede considerar la posibilidad de incluir otro tipo de información como entrada al modelo para que este realice la predicción de la radiación solar. De ahí se concibe la idea de analizar de manera más profunda la correlación existente entre las variables climáticas que no pertenecen al centro meteorológico donde es tomada la radiación solar, buscando incluir información útil ajena.

En la tabla 7, a partir de los valores  $P$  hallados para cada variable climática respecto a la radiación solar es posible determinar que no solo la información tomada en el mismo centro meteorológico es útil para la elaboración del modelo de pronóstico, debido a que muchas otras variables que se encuentran alejadas del punto de medición también poseen relación con este. En otras ocasiones puede ocurrir lo contrario, donde algunas variables pertenecientes al mismo punto donde se adquieren los datos no poseen mayor relación con las demás del mismo punto, como es el caso de la temperatura máxima en el punto 3 que no muestra estar relacionada con los puntos de medición.

A partir de las gráficas de la figura 10 donde es posible detallar los diagramas de autocorrelación de la radiación solar en cada uno de los puntos se puede determinar la relación que posee esta función con ella misma, a su vez permite evaluar la posibilidad de retrasar el valor de la radiación con el fin de establecer un mayor número de entradas para la red neuronal.

Durante el diseño de las redes neuronales que conformarían el modelo de predicción se tuvieron en cuenta los estudios realizados anteriormente, con el fin de profundizar en estos avances e implementar nuevos modelos y especificaciones a partir de las necesidades expuestas.

Al observar las gráficas obtenidas por el programa se puede percibir que aunque este entregue aproximaciones de la radiación solar estas no son muy precisas, por lo que se recomienda profundizar en este tema en investigaciones posteriores.

## 5. CONCLUSIONES Y CONSIDERACIONES FINALES

El uso de redes neuronales artificiales para la predicción de variables climáticas se convierte en una solución viable para el conocimiento de estos valores.

El hecho de introducir otras variables meteorológicas al sistema como lo son la temperatura máxima y mínima y las horas de sol puede representar una mejora significativa en la predicción del modelo, ya que este tiene en cuenta factores externos relacionados con la variable a predecir.

El implementar redes neuronales artificiales para la solución de problemas hace necesario realizar análisis de esta para determinar su punto óptimo, en el cual la red se puede producir un resultado más acorde al problema que los producidos por métodos tradicionales.

Puede llegar a ser un factor muy importante para los equipos que participan en la carrera del World Solar Challenge el llegar a conocer de manera aproximada el valor de radiación solar total adquirida por su vehículo, ya que esto les permitiría administrar de una mejor manera el gasto de energía a lo largo de toda la carrera.

Se puede determinar que aunque las redes neuronales artificiales pueden convertirse en una herramienta importante para la solución de problemas, estas también pueden entregar resultados menos exactos que los entregados con otras metodologías.

## BIBLIOGRAFÍA

*Paneles solares.* (2009). Recuperado el 16 de Septiembre de 2013, de Suministro solar:  
<http://www.suministrosolar.com/panelessolares>

*Calcular paneles y baterías para instalar energía solar en casa .* (13 de Mayo de 2013).  
Recuperado el 26 de Octubre de 2013, de Aytuto:  
<http://aytuto.blogspot.com/2013/05/calcular-paneles-y-baterias-para.html#.Um6APhD3NB8>

admin\_ulpgc. (28 de Febrero de 2012). *Predicción radiación solar.* Recuperado el 16 de Septiembre de 2013, de Investiga Universidad de las Palmas de Gran Canaria:  
<http://www.investigaulpgc.es/prediccion-radiacion-solar>

Benghanem, M., & Mellit, A. (2010). Radial Basis Function Network-based prediction of global solar radiation data: Application for sizing of a stand-alone photovoltaic system at Al-Madinah, Saudi Arabia. *Energy*, 12.

Bocco, M., Ovando, G., & Sayago, S. (s.f.). *ESTIMACIÓN DE LA RADIACIÓN SOLAR EN CÓRDOBA (ARGENTINA) MEDIANTE REDES NEURONALES.* Recuperado el 16 de Septiembre de 2013, de X Reunión Argentina y IV Latinoamericana de Agrometeorología: <http://agro.unc.edu.ar/~clima/AADA/Congresos/MDQ/84.htm>

Bustos, C. (s.f.). *APLICACIÓN DE REDES NEURONALES AL PRONÓSTICO DE TEMPERATURA MÍNIMA EN LA PROVINCIA DE MENDOZA.* Recuperado el 16 de Septiembre de 2013, de XI Congreso argentino de meteorología:  
<http://www.congremet.prmarg.org/upload/bustoscarlos1.pdf>

Cabaño, A. (Junio de 2010). *Variables estadísticas bidimensionales.* Recuperado el 23 de Octubre de 2013, de Aprender a pensar:  
[http://victormms.aprenderapensar.net/files/2010/06/variable\\_estadistica\\_bidimensionales.pdf](http://victormms.aprenderapensar.net/files/2010/06/variable_estadistica_bidimensionales.pdf)

*Clima en Australia.* (s.f.). Recuperado el 16 de Septiembre de 2013, de Portal Oceania:  
<http://www.portaloceania.com/au-diverses-climate-esp.htm>

Collantes, J. V. (2001). *PREDICCIÓN CON REDES NEURONALES: COMPARACIÓN CON LAS METODOLOGÍAS DE BOX Y JENKINS.* Recuperado el 16 de Septiembre de 2013, de Universidad de los Andes Venezuela:  
[http://tesis.ula.ve/postgrado/tde\\_archivos/16/TDE-2007-01-24T06:11:45Z-25/Publico/Joanna%20Collantes.pdf](http://tesis.ula.ve/postgrado/tde_archivos/16/TDE-2007-01-24T06:11:45Z-25/Publico/Joanna%20Collantes.pdf)

*INSTALACIONES CONECTADAS A LA RED.* (s.f.). Recuperado el 26 de Octubre de 2013, de Universidad de Castilla la Mancha: [http://www.info-ab.uclm.es/labelec/solar/solar\\_fotovoltaica/calculo\\_conectados.htm](http://www.info-ab.uclm.es/labelec/solar/solar_fotovoltaica/calculo_conectados.htm)

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Isasi Viñuela, P., & Galván León, I. M. (2004). En P. Isasi Viñuela , & I. Galván León , *Redes neuronales artificiales un enfoque práctico*. Pearson Prentice Hall.

Khatib, T., Mohamed, A., Sopian, K., & Mahmoud, M. (2012). *Solar Energy Prediction for Malaysia Using Artificial Neural Networks*. Recuperado el 16 de Septiembre de 2013, de Hindawi Publishing Corporation: <http://www.hindawi.com/journals/ijp/2012/419504/>

Llano, L., Hoyos, A., Arias, F., & Velásquez, J. (31 de Julio de 2007). *Comparación del Desempeño de Funciones de Activación en Redes Feedforward para aproximar Funciones de Datos con y sin Ruido*. Recuperado el 2013 de Octubre de 23, de Portal de revistas UN: <http://www.revistas.unal.edu.co/index.php/avances/article/viewFile/9756/10379>

Mejía, J. A. (07 de 12 de 2004). *Sistema de detección de intrusos en redes de comunicaciones utilizando redes neuronales*. Recuperado el 26 de 10 de 2013, de Colección de Tesis Digitales Universidad de las Américas Puebla: [http://catarina.udlap.mx/u\\_dl\\_a/tales/documentos/lep/mejia\\_s\\_ja/capitulo3.pdf](http://catarina.udlap.mx/u_dl_a/tales/documentos/lep/mejia_s_ja/capitulo3.pdf)

*Metodología para la evaluación del modelo de pronóstico meteorológico*. (s.f.). Recuperado el 26 de 10 de 2013, de Tesis Doctorales en Red: <http://www.tdx.cat/bitstream/handle/10803/6836/11Ojc11de12.pdf;jsessionid=A81D1A55C00B519CE4625698689B42A8.tdx2?sequence=11>

Ordóñez, H. (s.f.). *Estadística II*. Recuperado el 23 de Octubre de 2013, de Universidad Nacional de Colombia sede Manizales: [http://www.virtual.unal.edu.co/cursos/sedes/manizales/4030006/lecciones/capitulos/4\\_5\\_5.html](http://www.virtual.unal.edu.co/cursos/sedes/manizales/4030006/lecciones/capitulos/4_5_5.html)

Ovando, G., Bocco, M., & Sayago, S. (2005). *REDES NEURONALES PARA MODELAR PREDICCIÓN DE HELADAS*. Recuperado el 16 de Septiembre de 2013, de CHILEAN JOURNAL of AGRICULTURAL RESEARCH: <http://www.chileanjar.cl/online/espanol/v65n1/pdf/art7.pdf>

PELKOWSKI, J. (2003). *El problema de la predicción del tiempo desde el punto de vista de la mecánica y la física*. Recuperado el 30 de Marzo de 2013, de Revisa del Aficionado a la Meteorología: <http://www.tiempo.com/ram/1114/>

Quispe, R. (s.f.). *ECONOMETRIA II*. Recuperado el 23 de Octubre de 2013, de renanquispellanos: <http://renanquispellanos.com/recursos/CURSOECONOMETRIA/01AUTOCORRELACION%20forma%20causas%20consecuencias%20diagn%C3%B3stico.pdf>

*Regulations for the 2013 World Solar Challenge*. (s.f.). Recuperado el 26 de Octubre de 2013, de Bridgestone World Solar Challenge:

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



[http://www.worldsolarchallenge.org/files/7\\_regulations\\_for\\_2013\\_world\\_solar\\_challenge\\_release\\_copy\\_v11.pdf](http://www.worldsolarchallenge.org/files/7_regulations_for_2013_world_solar_challenge_release_copy_v11.pdf)

*Route Map.* (s.f.). Recuperado el 16 de Septiembre de 2013, de Bridgestone World Solar Challenge: [http://www.worldsolarchallenge.org/page/view\\_by\\_id/12](http://www.worldsolarchallenge.org/page/view_by_id/12)

Sayago, S., Bocco, M., Ovando, G., & Willington, E. (2011). *RADIACIÓN SOLAR HORARIA: MODELOS DE ESTIMACIÓN A PARTIR DE VARIABLES METEOROLÓGICAS BÁSICAS*. Recuperado el 16 de Septiembre de 2013, de Asociación Argentina de Energías Renovables y Ambiente: <http://www.asades.org.ar/modulos/averma/trabajos/2011/2011-t011-a008.pdf>

UNC, p. (14 de 11 de 2006). *Logran predecir la radiación solar en la UNC*. Recuperado el 16 de Septiembre de 2013, de Universia: <http://noticias.universia.com.ar/en-portada/noticia/2006/11/14/369031/logran-predecir-radiacion-solar-unc.html>

*World Solar Car Challenge.* (s.f.). Recuperado el 26 de Octubre de 2013, de Panasonic: <http://www.panasonic.com.au/Products/Solar+panels/World+Solar+Car+Challenge>

*World Solar Challenge - Control Point 2.* (s.f.). Recuperado el 16 de Septiembre de 2013, de Wikimapia: <http://wikimapia.org/12093192/World-Solar-Challenge-Control-Point-2>

Zeng, J., & Qiao, W. (2011). *Short-Term Solar Power Prediction Using an RBF Neural Network*. Recuperado el 16 de Septiembre de 2013, de DigitalCommons@UniversityofNebraska-Lincoln: <http://digitalcommons.unl.edu/cgi/viewcontent.cgi?article=1209&context=electricalengineeringfacpub>

## ANEXO 1

Datos obtenidos de Darwin Airport durante los meses de septiembre, octubre y noviembre del 2012															
Estación número: 014015					Latitud: 12.42° S			Longitud: 130.89° E			Elevación: 30 m				
Lluvia Units = mm12.3 = Not quality controlled.↓ = Part of accumulated total															
Temp max Units = °C. 12.3 = Not quality controlled or uncertain, or precise date unknown															
Temp min Units = °C. 12.3 = Not quality controlled or uncertain, or precise date unknown															
Radiacion					accumulated total										
2012	Sep	Oct	Nov		Sep	Oct	Nov		Sep	Oct	Nov		Sep	Oct	Nov
1st	6.9	5.6	7.6		0	3.2	0		34.2	31.3	34.9		20.8	22.6	26.7
2nd	7	7.5	8.2		0	0	0.8		35.5	34.2	34.1		20.4	23.0	25.6
3rd	6.9	7.7	7.5		0	0	33		35.5	35.1	33.4		19.5	22.7	23.2
4th	6.5	7	8.2		0	0.4	0		31.2	32.9	33.3		20.0	24.4	25.4
5th	6.8	7	7.4		0	0	0		32.3	33.9	32.9		20.8	24.6	25.8
6th	6.7	5.7	7.8		0	0	3		32.4	31.9	34.5		21.4	25.5	25.2
7th	6.8	7.6	7		0	0.6	0		32.3	32.6	33.3		21.6	22.7	26.2
8th	7.2	6.3	8.1		0	0	20		35.4	32.9	32.8		21.5	24.3	24.9
9th	7.1	7.4	7.7		0	0	0		36.2	34.2	33.1		22.1	24.3	25.5
10th	7.1	7.5	7.9		0	0	0		35.7	35.1	34.3		19.4	24.6	24.9
11th	7.2	7.8	7.7		0	0	0		35.1	33.9	33.9		21.4	25.6	25.0
12th	7.1	7.7	7.7		0	0	12		35.0	34.7	33.4		23.8	25.3	22.8
13th	6.9	7.9	7.5		0	0	3		33.0	36.6	33.8		21.2	23.5	23.7
14th	6.7	7.8	7.4		0	0	0		32.4	36.2	32.9		22.4	23.4	25.6
15th	7.3	7.1	7.6		0	0	2.2		33.8	34.4	33.4		21.8	24.3	24.9
16th	7	7	8.2		0	0	0		32.7	33.6	33.2		20.8	24.5	27.1
17th	6.6	7.3	8		0	0	0.5		32.2	34.8	33.1		21.2	26.2	26.3
18th	7.3	6	6.3		0	0.6	1		32.9	31.3	32.0		20.9	25.4	24.3
19th	7.4	7.4	8.1		0	1.2	0		33.1	33.2	33.3		22.6	24.5	25.7
20th	7.4	7.9	8.5		0	0	0		33.9	33.6	34.5		20.2	23.3	24.6
21st	7.1	8.1	8.4		0	0	0		33.1	33.3	34.0		20.7	24.8	26.1
22nd	7.4	8.1	8.5		0	0.6	0		34.7	33.4	34.6		22.9	24.2	27.2
23rd	7.5	8.2	7.1		0	0.6	0		33.8	35.2	32.4		22.5	24.2	27.9
24th	7.6	8.1	7		0	0.4	0		33.2	35.3	34.1		24.3	23.5	25.5
25th	7.5	7.3	8.4		0	0	0.4		35.5	33.6	35.7		23.3	25.4	24.4

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

26th	7.6	8.1	8.3		0	0.2	0		34.1	34.3	35.4		24.0	24.7	25.0
27th	7.6	7.9	8.4		0	0	0		33.7	34.1	35.9		23.9	25.2	26.5
28th	7.4	6.3	7.8		0	5.8	0		34.3	32.8	35.0		23.8	22.9	27.4
29th	7.4	8.2	7.7		0	3.2	3.6		33.6	34.2	33.5		24.1	23.3	24.8
30th	4.5	8.1	8.1		21	0	0.2		30.3	34.1	34.9		22.4	25.5	24.5
31st		8.2				0				34.4				26.0	
Sun hours				Max wind gust				Cld 9 am				Cld 3pm			
2012	Sep	Oct	Nov		Sep	Oct	Nov		Sep	Oct	Nov		Sep	Oct	Nov
1st	11.1	5.2	9.8		37	30	41		1	5	7		1	7	2
2nd	10.9	10.6	11		30	39	35		4	2	4		6	1	3
3rd	10.6	10.8	6.9		30	31	48		7	2	7		7	2	2
4th	9.5	10.4	9.1		37	39	52		5	3	6		6	1	4
5th	10.0	10.5	6.7		31	37	31		7	5	5		6	5	2
6th	9.6	6.3	9.2		33	31	39		1	7	7		3	6	7
7th	9.4	9.8	5.9		31	33	54		6	6	4		7	4	8
8th	10.6	8.8	8.7		44	35	37		0	1	4		2	6	6
9th	10.5	10.5	7.1		48	33	37		5	3	7		5	5	7
10th	10.5	10.9	8.6		39	30	39		4	6	7		6	4	3
11th	10.1	11.4	7.4		43	35	31		6	3	7		7	2	3
12th	10.6	9.2	8.3		35	44	44		5	7	4		5	3	5
13th	10.6	11.1	8.1		35	41	41		3	2	7		2	1	5
14th	10.3	11.0	9.7		39	37	33		2	5	7		2	6	7
15th	10.7	11.2	9.9		37	37	31		2	3	2		1	1	1
16th	10.7	9.4	10		37	35	37		2	2	4		2	4	5
17th	9.4	10.3	8.7		31	37	56		4	4	6		1	2	3
18th	10.9	3.8	1.8		31	41	26		1	6	7		1	8	7
19th	10.7	10.0	8.3		35	33	31		3	3	6		4	3	4
20th	10.9	10.6	12		37	35	30		2	1	3		4	1	2
21st	10.4	10.5	11		41	41	37		2	2	6		3	1	2
22nd	10.9	7.8	11		35	33	41		5	5	6		3	2	3
23rd	10.7	11.5	2.2		33	35	31		2	1	7		2	1	7
24th	10.8	11.3	6.2		33	41	52		2	4	4		1	2	7
25th	10.8	8.2	12		44	30	39		1	6	6		1	7	6
26th	10.8	10.0	12		31	35	39		4	7	2		1	3	2
27th	11.0	10.2	10		35	37	35		2	5	6		2	3	3
28th	10.6	4.4	6.5		35	57	31		4	8	6		1	5	7

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

29th	10.9	10.2	4.7		33	35	43		3	3	7		1	2	7
30th	2.4	10.5	9.2		57	30	35		8	5	6		6	1	6
31st		10.7				39				2				2	

Datos obtenidos de Katherine Country Club durante los meses de septiembre, octubre y noviembre del 2012															
Estación número: 014305					Latitud: 14.47° S				Longitud: 132.26° E				Elevación: 106 m		
					Lluvia Units = mm12.3 = Not quality controlled.↓ = Part of accumulated total				Temp max Units = °C. 12.3 = Not quality controlled or uncertain, or precise date unknown				Temp min Units = °C. 12.3 = Not quality controlled or uncertain, or precise date unknown		
Radiacion															
2012	Sep	Oct	Nov		Sep	Oct	Nov		Sep	Oct	Nov		Sep	Oct	Nov
1st	6.7	7.3	8.3		0	0	0		35.9	35	40.9		17.8	23	26.8
2nd	6.7	7.6	8.1		0	0	0		35.7	35	39.9		14.5	20	27.5
3rd	6.7	7.6	7.4		0	0	4.8		35.6	37	36.4		13.3	16	24.1
4th	6.6	6.3	8.1		0	0	0		35.4	37	39.4		15.5	22	23.7
5th	6.8	7	8.2		0	0	1.4		36.2	37			16.2	24	25.5
6th	6.7	6.6	7.3		0	0			36	37	38.2		20.1	26	
7th	6.8	7.4	7.8		0	0	10.8		36.8	39	36		18.5	24	24.2
8th	6.8	4.8	7.8		0	0.4	0		35.4	36	37.5		18.3	24	26.3
9th	6.8	7.3	5.8		0	0	0.8		35.1	39			18.3	25	23.5
10th	6.8	7.8	7.9		0	0	0		36	40	35.5		15.5	25	
11th	6.9	6.9	8.3		0	0	0		36.4	38	39.1		16.4		23.9
12th	6.9	7.8	7.9		0	0	0		37	35	39.9		18	21	26.5
13th	7	7.9	8.1		0	0	0		37.2	36	40.6		18	20	27.2
14th	6.9	7.9	7.7		0	0	0		36.5	38	39		21.2	20	25.9
15th	7	7.9	8.1		0	0	0		35.4	39	37.8		16.8	18	25.9
16th	7	7.5	8.2		0	0	0		35.7	40	38.6		15	24	27.8

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

17th	7	6.6	7.9		0	0	0		37.1	37	38.6		12.5	26	26.7
18th	7.1	6.3	7.9		0	0	5.8		37.5	37			16.9	27	23.3
19th	7.1	8	8.1		0	0	0		38.2	39	37.1		18.5	24	
20th	7	8.1	8.3		0	0	3.4		38.9	39	38.4		16.4	22	23.8
21st	7.1	8.1	8.2		0	0	0		39.2	40	39.8		17.8	23	26.1
22nd	7.2	7.7	8.7		0	1	2.8		39.3	39	39.9		19.5	25	26.2
23rd	7.3	7.9	6.9		0	0.6	0		40.1	40	34.2		19.5	24	25.7
24th	7.2	8	8		0	0	0		39.5	39	38.9		21.5	25	24.6
25th	7.3	7.8	8.7		0	0	0.6		38.9	39	39		21.9	25	24.5
26th	7.3	7.9	8.3		0	0	0		39.1	39	38.1		23.5	27	26.5
27th	7.3	7.3	8		0	1.2	0		40.4	39	39.2		24.1	26	25
28th	7.4	7.9	7.4		0	0	0		40.4	39	37		24.5	25	25.9
29th	6.9	8.2	7.5		0	0	0		36.4	40	36.9		24.1	25	26.4
30th	7.1	8.3	8		26.6	0	51.8		34.5	40	36.6		22.2	28	22.6
31st		8.3				0				41				28	
Sun hours					Max wind gust				Cld 9 am				Cld 3pm		
2012	Sep	Oct	Nov		Sep	Oct	Nov		Sep	Oct	Nov		Sep	Oct	Nov
1st					59	39	33		0	5	1			1	4
2nd					41	39	72		0	0	4		2	0	2
3rd					37	31	61		4	0	7		6	0	7
4th					31	39	39		4	7	0		7	4	3
5th					31	30	39		0	4	2		0	6	5
6th					31	26	35		0	3			4	5	
7th					37	41	39		0	0	3		4	4	8

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

8th					46		54		0	2	6		0	8	3
9th						33	35		2	1	8		2	4	8
10th						35	37		0	0			0	2	5
11th						41	37		2	2	2		0	6	5
12th						46	41		2	4	1		1	6	7
13th						41	41		2	0	5		0	0	6
14th						35	39		0	0	6		2	0	4
15th						35	28		0	0	3		0	0	3
16th						33	35		2	2	3		0	3	3
17th						44	44		0	0	7		0	6	4
18th						33	72		0	6	8		0	6	3
19th					39	39	67		0	0			0	1	6
20th					31	48	52		0	0	0		0	1	3
21st					43	43	44		0	1	2		0	2	3
22nd					37	37	41		0	0	3		0	3	2
23rd					35	50	39		2	2	7		0	3	8
24th					30	41	54		0	6	2		2	2	6
25th					30	26	31		0	5	2		2	3	4
26th					31	48	44		0	3	1		2	5	2
27th					35	33	39		0	8	1		4		6
28th					39	31	39		0	4	8		1	3	2
29th					41	28	70		4	0	7		3	4	7
30th					35	30	43		6	0	3		6	5	7
31st						39				0				3	

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Datos obtenidos de Daly Waters AWS durante los meses de septiembre, octubre y noviembre del 2012															
Estación número: 014626					Latitud: 16.26° S				Longitud: 133.38° E				Elevación: 210 m		
Lluvia Units = mm12.3 = Not quality controlled.↓ = Part of accumulated totalTemp max Units = °C. 12.3 = Not quality controlled or uncertain, or precise date unknownTemp min Units = °C. 12.3 = Not quality controlled or uncertain, or precise date unknown															
Radiacion															
2012	Sep	Oct	Nov		Sep	Oct	Nov		Sep	Oct	Nov		Sep	Oct	Nov
1st	6.6	7.6	8.3		0	0.2	0		35	34			18	20	23
2nd	6.6	7.6	7.1		0	0			35	35			9.6	20	
3rd	6.6	7.6	7.9		0	0			35	36			9.1	12	
4th	6.6	6.7	7.7		0	0			36	38			8.6	18	
5th	6.7	6	7.9		0	0			36	37			11	22	
6th	6.3	7.6	7.1		0	0			36	38			13	18	
7th	6.8	7.2	7.7		0	0			37	38	39		15	18	
8th	6.8	7	7.7		0	0	0		33	39	39		19	19	24
9th	6.8	7.6	6.5		0	0	2.6		33	41	34		16	19	23
10th	6.8	7.7	8.4		0	0			35	41	37		8.4	19	21
11th	6.9	6.6	8.2		0	0	0.4		37	31	40		12	23	22
12th	6.9	7.7	7.9		0	0	0		37	33	41		13	18	23
13th	7	7.8	8.4		0	0	0		38	34	39		11	16	23
14th	7	7.8	7.7		0	0	0		36	38	41		17	9.9	25
15th	7.1	7.8	8.6		0	0	0		35	39	40		18	11	23
16th	7.1	7.6	8.3		0	0	0		35	39	40		8.8	17	25
17th	7.1	6.3	8		0	0	0		37	37	39		7.6	22	26
18th	7.1	7.4	6.7		0	0	2.2		37	39	37		11	21	24

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

19th	7.2	8.1	8.7		0	0	33		38	39	38		12	17	22
20th	7.2	8	8.5		0	0	5		38	39	40		12	17	25
21st	7.2	8	8.6		0	0.6	0		39	39	42		13	20	24
22nd	7.3	8.1	8.6		0	0	0		39	40	42		15	19	26
23rd	7.3	7.7	8.1		0	0	0		40	40	39		18	17	27
24th	7.3	8.2	8.1		0	0	0		38	40	38		15	21	24
25th	7.4	8.1	8.7		0	0	0		39	39	40		16	18	26
26th	7.4	7.3	8		0	0	0		39	39	40		18	22	23
27th	7.4	8.3	7.8		0	20	6		41	38	38		18	23	23
28th	7.4	8.3	8.3		0	0	1.2		39	38	39		20	21	24
29th	5.8	8.3	5.4		0	0	1.2		36	39	34		26	18	26
30th	6.2	8.4	8.2		1	0	25		35	40	36		22	17	22
31st		8.3				0				38				20	
Sun hours				Max wind gust				Cld 9 am				Cld 3pm			
2012	Sep	Oct	Nov		Sep	Oct	Nov		Sep	Oct	Nov		Sep	Oct	Nov
1st					30	39									
2nd					26	41									
3rd					30	26									
4th					33	31									
5th					26	33									
6th					30	31									
7th					28	33	24								
8th					35	39	50								
9th					35	35									

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



10th					37	56	33								
11th					35	44	35								
12th					28	41	43								
13th					39	33	35								
14th					43	33	30								
15th					39	28	37								
16th					26	26	28								
17th					31	44	44								
18th					35	30	44								
19th					28	33	46								
20th					35	39	26								
21st					39	37	24								
22nd					24	39	28								
23rd					31	37	52								
24th					26	39	37								
25th					24	35	24								
26th					39	63	35								
27th					30	24	39								
28th					33	31	33								
29th					33	30	69								
30th					26	24	37								
31st						31									

Datos obtenidos de Tennant Creek Airport durante los meses de septiembre, octubre y noviembre del 2012

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Estación número: 015135					Latitud: 19.64° S				Longitud: 134.18° E				Elevación: 376 m		
					Lluvia Units = mm12.3 = Not quality controlled.↓ = Part of accumulated total				Temp max Units = °C. 12.3 = Not quality controlled or uncertain, or precise date unknown				Temp min Units = °C. 12.3 = Not quality controlled or uncertain, or precise date unknown		
Radiacion															
2012	Sep	Oct	Nov		Sep	Oct	Nov		Sep	Oct	Nov		Sep	Oct	Nov
1st	6.4	6.1	8.3		0	0	0		27.7	28.2	40.0		15.3	15.9	23.7
2nd	6.4	7.5	8.3		0	0	0		28.8	29.2	41.4		14.7	16.5	25.9
3rd	6.4	7.5	8.1		0	0	0		31.0	34.1	39.9		14.0	18.1	26.6
4th	6.4	7.3	7.4		0	0	0		31.7	35.1	40.5		15.8	19.4	24.3
5th	6.5	6.5	7.3		0	0	1.4		35.0	35.3	37.5		18.2	25.3	26.4
6th	6.6	7.6	4.2		0	0	0.8		34.2	36.7	26.8		18.4	22.7	22.4
7th	6.6	7.6	8.3		0	0	0.8		33.1	37.0	36.6		18.3	22.3	20.2
8th	6.6	7.6	6.8		0	0	0.6		26.0	38.0	33.2		14.4	23.2	22.8
9th	6.5	7.6	6.9		0	0	0		26.4	39.6	28.9		13.3	23.6	19.9
10th	6.6	6.3	8.6		0	0	0		30.4	40.3	33.0		15.3	25.3	18.6
11th	6.7	7.7	8.7		0	0.6	0		32.5	28.0	35.6		18.0	19.1	21.8
12th	6.7	7.7	8.7		0	0	0		34.1	27.6	38.1		18.8	14.2	24.9
13th	6.7	7.8	8.4		0	0	0		34.4	29.6	38.8		18.8	14.8	24.8
14th	6.8	7.8	8.4		0	0	0		28.7	32.7	38.8		16.0	15.8	24.4
15th	6.8	7.8	8.6		0	0	0		28.8	35.3	39.3		15.6	19.5	24.1
16th	6.8	7.8	8.6		0	0	0		30.2	37.0	39.9		14.3	21.6	25.9
17th	6.9	7.7	7.6		0	0	0		32.3	37.4	41.1		17.4	22.9	27.7
18th	6.9	7.7	8.4		0	0	0		35.7	37.4	38.6		18.6	22.9	24.9
19th	7	8.1	8.6		0	0	17		37.0	38.2	38.6		21.0	22.3	22.9
20th	7.1	8.1	8.7		0	0	0		37.5	38.3	39.7		21.7	23.6	23.5

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

21st	7.1	8.1	8.8		0	0	0		38.3	38.3	41.1		21.7	24.0	25.2
22nd	7.1	8.2	8.8		0	0	0		37.9	38.9	40.9		22.4	22.7	26.1
23rd	7	8.1	8.7		0	0	0		38.7	39.5	42.2		23.6	23.6	27.6
24th	5.4	7.8	8		0	0	0		30.3	38.9	40.6		21.1	25.5	22.8
25th	6.8	8.1	8.2		0	0	1.8		35.2	37.6	39.9		21.9	24.2	24.7
26th	7.1	6.1	8.2		0	0.8	0		37.5	28.4	38.0		23.5	20.5	26.3
27th	4.6	8.3	6.8		0	1.8	0		38.4	31.6	38.1		23.1	16.9	25.9
28th	4.3	8.3	8.4		6.2	0	0		37.6	32.7	41.1		23.3	19.8	25.8
29th	4.7	8.4	7.5		2.8	0	60		26.1	35.0	35.1		19.2	20.6	19.6
30th	7.4	8.4	8.6		0	0	0		28.6	37.3	38.5		14.3	20.6	24.4
31st		8.4				0								21.6	
Sun hours				Max wind gust				Cld 9 am				Cld 3pm			
2012	Sep	Oct	Nov		Sep	Oct	Nov		Sep	Oct	Nov		Sep	Oct	Nov
1st	11.1	8.3	11.5		54	52	35			0	6	0		0	5
2nd	11.3	11.8	11.6		43	57	48			0	1	0		0	0
3rd	11.2		9.5		39	41	39			0	1	2		0	0
4th	11.3		7.8		30	43	46			0		1		1	
5th	11		6		41	39	43			0	3	6		0	5
6th	10.9	11.4	0.1		30	39	44			1	0	7		1	1
7th	10.9	11.6	9.1		54	48	35			0	1	1		0	1
8th	11.3	11.8	4.6		54	48	50			0	0	7		0	1
9th	11.4	11	5.9		44	28	41			0	0	8		5	1
10th	11.3	6.9	12.6		52	52	44			0	2	0		1	7
11th	11.2	11.1	12.5		52	59	44			0	3	0		0	1

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

12th	11.3	11.6	12.6		50	50	54			1	0	1		1	0
13th	11.4	11.7	12.1		48	52	50			0	0	0		0	0
14th	11.1	11.8	12		57	43	44			0	0	3		0	0
15th	11.2	11.9	12.5		50	43	44			0	0	0		0	0
16th	11.2	11.8	11.2		33	35	39			0	0	0		0	1
17th	11.3	11.5	6.9		46	35	43			0	0	6		0	3
18th	11.2	12	9.1		44	35	72			0	0	5		1	1
19th	10.7	12.1	11.3		41	35	35			0	0	0		0	1
20th	10.8	11.9	11.8		39	50	28			0	1	0		1	4
21st	10.6	12	12.8		35	39	57			2	1	1		1	1
22nd	10.9	12	12.4		33	63	50			0	1	1		0	1
23rd	7.4	10.5	12.5		46	46	41			3	0	1		1	3
24th	3.3	10.5	8.5		46	41	63			7	3	3		6	4
25th	7.8	11.6	9.3		43	39	39			7	1	0		1	3
26th	9.5	3.1	8.3		52	44	48			1	8	6		0	6
27th	3.5	12	5.3		50	41	48			7	0	7		3	0
28th	4.4	12.4	10.1		39	48	39			8	0	6		4	0
29th	3.2	12.4	7		50	41	70			4	1	8		8	1
30th	11.6	12.5	10.5		52	41	43			1	0	2		1	0
31st		12.5				41					0				0

---

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Datos obtenidos de Territory Grape Farm durante los meses de septiembre, octubre y noviembre del 2012															
Estación número: 015643					Latitud: 22.45° S				Longitud: 133.64° E				Elevación: 566 m		
Lluvia Units = mm12.3 = Not quality controlled.↓ = Part of accumulated totalTemp max Units = °C. 12.3 = Not quality controlled or uncertain, or precise date unknownTemp min Units = °C. 12.3 = Not quality controlled or uncertain, or precise date unknown															
Radiacion															
2012	Sep	Oct	Nov		Sep	Oct	Nov		Sep	Oct	Nov		Sep	Oct	Nov
1st	6.1	7.3	8.4		0	0	0		26	27	40		5.6	8.2	17
2nd	6.1	7.4	8.4		0	0	0		27	27	39		5.2	8.7	20
3rd	6.1	7.4	6.8		0		0		29	32	38		8.1	8.3	20
4th	6.2	7.4	7.2		0	0	0		32	36	41		5.5	14	21
5th	6.3	7.1	5.4		0	0	2.2		33	37	34		9.8	22	22
6th	6.3	6.8	5.9		0	0	3.8		33	37	28		11	22	19
7th	6.3	7	8.3		0	0	1.8		26	37	35		12	21	17
8th	6.3	7.4	7.5		0	0	28		24	38	32		6.2	19	19
9th	5.9	7.3	8.5		0	0	2.4		25	39	29		4.7	20	16
10th	6.4	4.3	8.7		0	0	0		28	33	30		5.7	25	15
11th	6.4	7.6	8.7		0	0	0		30	26	32		7.9	12	16
12th	6.5	7.7	8.7			0	0		32	26	36		10	7.6	18
13th	6.6	7.7	8.8		0	0	0		29	28	37		9.3	6.6	20
14th	6.6	7.7	8.8		0	0	0		26	32	37		8.9	11	21
15th	6.6	7.7	8.8		0	0	0		26	34	39		6.1	10	19
16th	6.7	7.8	8		0	0	0		29	37	40		7	12	21
17th	6.7	7.8	8.7		0	0	0		31	38	39		7.6	15	22
18th	6.8	7.6	8.8		0	0	0		35	38	37		10	15	20

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

19th	6.4	8	8.8		0	0	0		37	38	38		16	17	19
20th	6.9	7.8	8.7		0	0	0		38	38	39		17	17	19
21st	6.9	8.1	8.8		0	0	0		37	38	39		17	18	20
22nd	6.9	8.1	8.8		0	0	0		38	39	39		19	18	23
23rd	6.8	8.1	8.8		0	0	0		32	40	41		19	21	24
24th	6.8	7.7	8.2		0	0	0		32	39	40		15	20	25
25th	7	8.1	8.1			0.2	0		34	34	41		18	22	25
26th	4.5	5.6	7		0	2.8	0		34	24	37		14	15	24
27th	7.2	8.3	6.4		0	3	0		38	29	36		18	12	26
28th	6.9	8.3	8.8		0.2	0	0		38	30	40		20	13	26
29th	4	8.3	8		0.8	0	0		22	33	41		18	12	26
30th	7.3	8.4	7.6		0.8	0	0		27	35	39		7.2	14	26
31st		8.4				0				38				16	
Sun hours				Max wind gust				Cld 9 am				Cld 3pm			
2012	Sep	Oct	Nov		Sep	Oct	Nov		Sep	Oct	Nov		Sep	Oct	Nov
1st					43	43	39								
2nd					28	46	44								
3rd					35	43	39								
4th					30	35	44								
5th					43	43	48								
6th					43	31	59								
7th					44	30	52								
8th					52	30	74								
9th					41	61	43								

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

10th					31	52	35								
11th					31	48	37								
12th					31	44	35								
13th					46	31	39								
14th					41	30	39								
15th					37	33	37								
16th					26	28	56								
17th					24	31	35								
18th					46	37	44								
19th					39	33	35								
20th					37	41	33								
21st					31	41	35								
22nd					26	41	48								
23rd					41	41	41								
24th					37	70	41								
25th					26	46	65								
26th					30	44	30								
27th					44	43	31								
28th					67	37	33								
29th					35	31	37								
30th					44	28	48								
31st						30									

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

## ANEXO 2

	RP1	TMaP1	TMiP1	SHP1	RP2	TMaP 2	TMiP 2	RP 3	TMaP 3	TMiP 3	RP 4
N	X0	X2	X3	X4	X8	X10	X11	X16	X18	X19	X24
1	6.9	34.2	20.8	11.1	6.7	35.9	17.8	6.6	34.7	17.9	6.4
2	7	35.5	20.4	10.9	6.7	35.7	14.5	6.6	34.7	9.6	6.4
3	6.9	35.5	19.5	10.6	6.7	35.6	13.3	6.6	35.2	9.1	6.4
4	6.5	31.2	20.0	9.5	6.6	35.4	15.5	6.6	35.6	8.6	6.4
5	6.8	32.3	20.8	10.0	6.8	36.2	16.2	6.7	36.4	10.8	6.5
6	6.7	32.4	21.4	9.6	6.7	36	20.1	6.3	36	13.4	6.6
7	6.8	32.3	21.6	9.4	6.8	36.8	18.5	6.8	36.7	14.9	6.6
8	7.2	35.4	21.5	10.6	6.8	35.4	18.3	6.8	33.3	19.4	6.6
9	7.1	36.2	22.1	10.5	6.8	35.1	18.3	6.8	32.5	16.3	6.5
10	7.1	35.7	19.4	10.5	6.8	36	15.5	6.8	35.4	8.4	6.6
11	7.2	35.1	21.4	10.1	6.9	36.4	16.4	6.9	36.8	12.2	6.7
12	7.1	35.0	23.8	10.6	6.9	37	18	6.9	36.9	13.4	6.7
13	6.9	33.0	21.2	10.6	7	37.2	18	7	37.8	11.3	6.7
14	6.7	32.4	22.4	10.3	6.9	36.5	21.2	7	35.6	17.4	6.8
15	7.3	33.8	21.8	10.7	7	35.4	16.8	7.1	34.6	18.4	6.8
16	7	32.7	20.8	10.7	7	35.7	15	7.1	34.6	8.8	6.8
17	6.6	32.2	21.2	9.4	7	37.1	12.5	7.1	36.8	7.6	6.9
18	7.3	32.9	20.9	10.9	7.1	37.5	16.9	7.1	37.4	10.5	6.9
19	7.4	33.1	22.6	10.7	7.1	38.2	18.5	7.2	38.2	12.2	7
20	7.4	33.9	20.2	10.9	7	38.9	16.4	7.2	38.2	12.3	7.1
21	7.1	33.1	20.7	10.4	7.1	39.2	17.8	7.2	38.7	13.4	7.1
22	7.4	34.7	22.9	10.9	7.2	39.3	19.5	7.3	39.4	15.1	7.1
23	7.5	33.8	22.5	10.7	7.3	40.1	19.5	7.3	39.5	18.1	7
24	7.6	33.2	24.3	10.8	7.2	39.5	21.5	7.3	38.2	15.4	5.4
25	7.5	35.5	23.3	10.8	7.3	38.9	21.9	7.4	39.1	16.3	6.8
26	7.6	34.1	24.0	10.8	7.3	39.1	23.5	7.4	38.6	17.9	7.1
27	7.6	33.7	23.9	11.0	7.3	40.4	24.1	7.4	40.9	18.4	4.6
28	7.4	34.3	23.8	10.6	7.4	40.4	24.5	7.4	39	19.5	4.3
29	7.4	33.6	24.1	10.9	6.9	36.4	24.1	5.8	36.4	25.6	4.7
30	4.5	30.3	22.4	2.4	7.1	34.5	22.2	6.2	34.5	22.2	7.4
31	5.6	31.3	22.6	5.2	7.3	35.1	23.2	7.6	34.3	20.4	6.1

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



32	7.5	34.2	23.0	10.6	7.6	35.1	20.2	7.6	35.2	19.6	7.5
33	7.7	35.1	22.7	10.8	7.6	36.5	16.1	7.6	36	11.7	7.5
34	7	32.9	24.4	10.4	6.3	37.3	22	6.7	37.7	17.5	7.3
35	7	33.9	24.6	10.5	7	37	23.5	6	36.6	22.1	6.5
36	5.7	31.9	25.5	6.3	6.6	36.7	25.5	7.6	37.6	18.4	7.6
37	7.6	32.6	22.7	9.8	7.4	38.6	24.3	7.2	37.6	17.8	7.6
38	6.3	32.9	24.3	8.8	4.8	36	24.4	7	38.9	19.1	7.6
39	7.4	34.2	24.3	10.5	7.3	39.4	25.3	7.6	40.6	19.2	7.6
40	7.5	35.1	24.6	10.9	7.8	39.9	25.2	7.7	40.9	18.9	6.3
41	7.8	33.9	25.6	11.4	6.9	38		6.6	30.6	23.4	7.7
42	7.7	34.7	25.3	9.2	7.8	35.4	20.6	7.7	32.8	17.5	7.7
43	7.9	36.6	23.5	11.1	7.9	35.9	20	7.8	34.1	16	7.8
44	7.8	36.2	23.4	11.0	7.9	37.5	19.6	7.8	37.7	9.9	7.8
45	7.1	34.4	24.3	11.2	7.9	38.6	18.4	7.8	38.7	11.2	7.8
46	7	33.6	24.5	9.4	7.5	39.5	23.6	7.6	38.5	16.5	7.8
47	7.3	34.8	26.2	10.3	6.6	37.2	26.1	6.3	37.3	22.3	7.7
48	6	31.3	25.4	3.8	6.3	36.7	26.6	7.4	39.1	20.5	7.7
49	7.4	33.2	24.5	10.0	8	38.7	23.8	8.1	38.7	17.2	8.1
50	7.9	33.6	23.3	10.6	8.1	38.8	21.9	8	39.3	16.6	8.1
51	8.1	33.3	24.8	10.5	8.1	39.5	23.4	8	38.7	20.4	8.1
52	8.1	33.4	24.2	7.8	7.7	39.4	25.1	8.1	39.8	18.8	8.2
53	8.2	35.2	24.2	11.5	7.9	39.9	24.1	7.7	40.4	17.3	8.1
54	8.1	35.3	23.5	11.3	8	39.1	24.7	8.2	40.2	20.7	7.8
55	7.3	33.6	25.4	8.2	7.8	38.5	24.5	8.1	39.3	17.8	8.1
56	8.1	34.3	24.7	10.0	7.9	39.4	26.8	7.3	39.2	21.7	6.1
57	7.9	34.1	25.2	10.2	7.3	38.5	25.5	8.3	37.8	22.5	8.3
58	6.3	32.8	22.9	4.4	7.9	39.3	25.4	8.3	37.5	20.9	8.3
59	8.2	34.2	23.3	10.2	8.2	40.1	24.8	8.3	39.1	17.7	8.4
60	8.1	34.1	25.5	10.5	8.3	39.9	27.5	8.4	39.6	17.2	8.4
61	8.2	34.4	26.0	10.7	8.3	40.6	27.9	8.3	38.4	19.7	8.4
62	7.6	34.9	26.7	9.8	8.3	40.9	26.8	8.3		23.3	8.3
63	8.2	34.1	25.6	11.3	8.1	39.9	27.5	7.1			8.3
64	7.5	33.4	23.2	6.9	7.4	36.4	24.1	7.9			8.1
65	8.2	33.3	25.4	9.1	8.1	39.4	23.7	7.7			7.4
66	7.4	32.9	25.8	6.7	8.2		25.5	7.9			7.3
67	7.8	34.5	25.2	9.2	7.3	38.2		7.1			4.2

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

68	7	33.3	26.2	5.9	7.8	36	24.2	7.7	38.9		8.3
69	8.1	32.8	24.9	8.7	7.8	37.5	26.3	7.7	39.2	24.4	6.8
70	7.7	33.1	25.5	7.1	5.8		23.5	6.5	34.4	22.8	6.9
71	7.9	34.3	24.9	8.6	7.9	35.5		8.4	36.9	21.1	8.6
72	7.7	33.9	25.0	7.4	8.3	39.1	23.9	8.2	39.5	21.5	8.7
73	7.7	33.4	22.8	8.3	7.9	39.9	26.5	7.9	40.6	22.8	8.7
74	7.5	33.8	23.7	8.1	8.1	40.6	27.2	8.4	39.1	22.7	8.4
75	7.4	32.9	25.6	9.7	7.7	39	25.9	7.7	40.7	25.3	8.4
76	7.6	33.4	24.9	9.9	8.1	37.8	25.9	8.6	40.1	23.1	8.6
77	8.2	33.2	27.1	10.1	8.2	38.6	27.8	8.3	39.9	24.5	8.6
78	8	33.1	26.3	8.7	7.9	38.6	26.7	8	39.4	26.2	7.6
79	6.3	32.0	24.3	1.8	7.9		23.3	6.7	37.3	23.8	8.4
80	8.1	33.3	25.7	8.3	8.1	37.1		8.7	38.4	21.9	8.6
81	8.5	34.5	24.6	11.7	8.3	38.4	23.8	8.5	39.8	25	8.7
82	8.4	34.0	26.1	11.1	8.2	39.8	26.1	8.6	41.6	23.5	8.8
83	8.5	34.6	27.2	11.2	8.7	39.9	26.2	8.6	41.9	25.8	8.8
84	7.1	32.4	27.9	2.2	6.9	34.2	25.7	8.1	39.3	26.9	8.7
85	7	34.1	25.5	6.2	8	38.9	24.6	8.1	38.1	24.2	8
86	8.4	35.7	24.4	11.7	8.7	39	24.5	8.7	40	25.7	8.2
87	8.3	35.4	25.0	11.7	8.3	38.1	26.5	8	40.1	23.4	8.2
88	8.4	35.9	26.5	10.3	8	39.2	25	7.8	38	23.3	6.8
89	7.8	35.0	27.4	6.5	7.4	37	25.9	8.3	39.4	24.1	8.4
90	7.7	33.5	24.8	4.7	7.5	36.9	26.4	5.4	33.8	25.9	7.5
91	8.1	34.9	24.5	9.2	8	36.6	22.6	8.2	36.2	22.4	8.6

TMaP4	TMiP4	RP5	TMaP5	TMiP5
X26	X27	X32	X34	X35
27.7	15.3	6.1	25.9	5.6
28.8	14.7	6.1	27	5.2
31.0	14.0	6.1	28.6	8.1
31.7	15.8	6.2	32	5.5
35.0	18.2	6.3	33	9.8
34.2	18.4	6.3	32.6	11.1
33.1	18.3	6.3	26.3	12
26.0	14.4	6.3	23.9	6.2
26.4	13.3	5.9	25.1	4.7
30.4	15.3	6.4	28	5.7

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

32.5	18.0	6.4	30.3	7.9
34.1	18.8	6.5	32.3	10.2
34.4	18.8	6.6	28.7	9.3
28.7	16.0	6.6	26.2	8.9
28.8	15.6	6.6	25.8	6.1
30.2	14.3	6.7	29.3	7
32.3	17.4	6.7	31.3	7.6
35.7	18.6	6.8	35.1	10.3
37.0	21.0	6.4	37.1	16
37.5	21.7	6.9	37.7	16.7
38.3	21.7	6.9	37.4	17.2
37.9	22.4	6.9	37.8	18.6
38.7	23.6	6.8	32	18.8
30.3	21.1	6.8	31.9	14.8
35.2	21.9	7	34.1	17.5
37.5	23.5	4.5	34.4	13.7
38.4	23.1	7.2	38.2	17.9
37.6	23.3	6.9	37.8	20.4
26.1	19.2	4	22.1	17.6
28.6	14.3	7.3	26.8	7.2
28.2	15.9	7.3	26.8	8.2
29.2	16.5	7.4	26.5	8.7
34.1	18.1	7.4	31.5	8.3
35.1	19.4	7.4	35.7	14.3
35.3	25.3	7.1	36.5	21.7
36.7	22.7	6.8	37.2	22.4
37.0	22.3	7	36.5	20.5
38.0	23.2	7.4	37.7	18.7
39.6	23.6	7.3	39.3	20.2
40.3	25.3	4.3	32.7	24.9
28.0	19.1	7.6	25.8	12
27.6	14.2	7.7	26.1	7.6
29.6	14.8	7.7	28	6.6
32.7	15.8	7.7	31.6	10.6
35.3	19.5	7.7	34.4	10.2
37.0	21.6	7.8	36.5	12.4

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

37.4	22.9	7.8	37.7	14.8
37.4	22.9	7.6	38.2	15.1
38.2	22.3	8	38.2	16.5
38.3	23.6	7.8	38	16.8
38.3	24.0	8.1	38	18.3
38.9	22.7	8.1	39.1	18.4
39.5	23.6	8.1	39.5	20.9
38.9	25.5	7.7	39.2	20
37.6	24.2	8.1	34.4	22
28.4	20.5	5.6	24.4	14.6
31.6	16.9	8.3	28.8	11.7
32.7	19.8	8.3	30.1	13.3
35.0	20.6	8.3	32.7	12.1
37.3	20.6	8.4	35.3	14.2
	21.6	8.4	37.9	15.6
40.0	23.7	8.4	39.8	17.1
41.4	25.9	8.4	39	19.8
39.9	26.6	6.8	38.2	19.8
40.5	24.3	7.2	40.8	21.3
37.5	26.4	5.4	33.8	22
26.8	22.4	5.9	28.4	18.9
36.6	20.2	8.3	34.7	17.3
33.2	22.8	7.5	31.5	18.8
28.9	19.9	8.5	28.9	16.4
33.0	18.6	8.7	30.3	14.6
35.6	21.8	8.7	32.2	15.7
38.1	24.9	8.7	35.5	18.2
38.8	24.8	8.8	36.6	20.3
38.8	24.4	8.8	36.9	20.5
39.3	24.1	8.8	39	19.1
39.9	25.9	8	39.8	21.1
41.1	27.7	8.7	39.1	21.9
38.6	24.9	8.8	36.6	19.8
38.6	22.9	8.8	38.1	18.9
39.7	23.5	8.7	38.7	19.3
41.1	25.2	8.8	39.4	19.7

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

40.9	26.1	8.8	39	23
42.2	27.6	8.8	40.6	23.9
40.6	22.8	8.2	39.7	25.2
39.9	24.7	8.1	40.7	24.8
38.0	26.3	7	36.8	24.3
38.1	25.9	6.4	36.1	26.2
41.1	25.8	8.8	40.1	25.5
35.1	19.6	8	40.6	25.6
38.5	24.4	7.6	39.4	26.1

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

## ANEXO 3

```
Public Class Form1
    Public OXL As Object
    Public OWB As Object
    Public Ruta As String
    'Se definen las variables que guardan el valor del número de neuronas y
    número de datos.
    Dim i As Long, j As Long
    Dim i1 As Long, ND As Long
    Dim NO As Long, NE As Long
    Public X(,) As Double, k As Long
    'Se crean las variables que almacenan los valores de los pesos, los datos, la
    salida obtenida y deseada y los errores.
    Public W(,) As Double, W1(,) As Double, W2(,) As Single, S() As Double
    Public C() As Double, yr() As Double
    Public yd() As Double, er1, ers, ERSV As Double
    Dim alfa As Single, NIT As Long, M As Single
    Dim ITO As Single
    Dim num = 0
    Dim calf = 0
    Dim NP, NV As Long
    'Se define el tipo de variables para la red neuronal base radial
    Dim XC(), YC(), XBR(), YBR(), S1() As Single
    Dim hx(,), hy(,) As Double

    Private Sub Form1_Load(ByVal sender As System.Object, ByVal e As
    System.EventArgs) Handles MyBase.Load

        End Sub

        'Se inicia con la programación de la red neuronal.
        Private Sub Button2_Click(ByVal sender As System.Object, ByVal e As
        System.EventArgs) Handles Button2.Click

            'Se pide al usuario que ingrese el número de datos, entradas e iteraciones.
            ND = Val(InputBox("Ingresar Número de Datos", , 86))
            NE = Val(InputBox("Ingresar Número de Entradas", , 84))
            NIT = Val(InputBox("Ingresar Número de Iteraciones", , 10000))
            calf = 0
            'Se inicia el programa.
            For g = 1 To 3
                num = 0
                Select Case calf
                    Case 0
                        alfa = 0.005
                        calf = calf + 1
                    Case 1
                        alfa = 0.001
                        calf = calf + 1
```

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

```

Case 2
    alfa = 0.0005
    calf = calf + 1
End Select
For h = 1 To 5
    Ruta = Application.StartupPath
    OXL = CreateObject("Excel.Application")
    OWB = OXL.Workbooks.Open(Ruta & "\EDEFNP1")
    OXL.Visible = True
    Me.Activate()

    'Se define el número de neuronas en la capa oculta.
    Select Case num
        Case 0
            NO = 50
            num = num + 1
        Case 1
            NO = 100
            num = num + 1
        Case 2
            NO = 150
            num = num + 1
        Case 3
            NO = 200
            num = num + 1
        Case 4
            NO = 250
            num = num + 1
    End Select

    ReDim X(ND, NE), W(NO, NE), W1(NO, NE), W2(NO, NE), S(NO), yr(ND)
    ReDim C(NO), yd(ND)
    'Los datos son leídos de la hoja de la hoja de Excel y almacenados
    en la variable X(.). De igual forma la salida deseada es almacenada en yd().
    For k = 1 To ND
        For i = 1 To NE
            X(k, i) = Val(OWB.Worksheets(1).cells(k + 2, 1 + i).value)
            'OWB.Worksheets(1).cells(k + 2, 6 + 17).value = X(k, 17)
        Next i

        yd(k) = Val(OWB.Worksheets(1).cells(k + 2, NE + 3).value)
        'OWB.Worksheets(1).cells(k + 2, NE + 4).value = yd(k)

    Next
    Randomize()

    'Se comienzan a generar los pesos de las neuronas ocultas de manera
    aleatoria y almacenados en la variable W(.), los valores de los pesos se dividen
    para evitar errores durante el aprendizaje.
    For j = 1 To NO
        For i = 1 To NE

```

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

```

        W(j, i) = (Rnd()) / 100
    Next i
    C(j) = (Rnd()) / 100
Next j

'Inicia el proceso de aprendizaje (Proceso Feedforward).
'Los valores de la salida yr() y el error con respecto a la salida
deseada yd() son obtenidos y almacenados.
Dim ERS As Single
Dim SERS As Double
SERS = 0
For i1 = 1 To NIT
    ERS = 0
    For k = 1 To ND
        yr(k) = 0
        For j = 1 To NO
            S(j) = 0
            For i = 1 To NE
                S(j) = S(j) + X(k, i) * W(j, i)
            Next i
            yr(k) = yr(k) + C(j) * S(j)
        Next j
        OWB.Worksheets(1).cells(k + 2, NE + 4).value = yr(k)
        er1 = yd(k) - yr(k)
        OWB.Worksheets(1).cells(k + 2, NE + 5).value = er1
        ERS = ERS + Math.Pow(er1, 2)
        'Los valores de los pesos se corrigen a partir del error
obtenido, cambiando los valores de los pesos ocasionando el aprendizaje de la red
neuronal.

        For j = 1 To NO
            C(j) = C(j) + alfa * er1 * S(j)

            For i = 1 To NE
                W(j, i) = W(j, i) + (C(j) * er1) * alfa * X(k, i)

            Next i
        Next j
    Next k
    'Se crea una condicional para salir del programa cuando el error
RMSE sea menor a 0.001.
    If ERS <= 0.001 Then
        i1 = NIT
    End If
    ERS = Math.Sqrt(ERS / ND)
    OWB.Worksheets(1).cells(i1 + 2, NE + 9).value = ERS
    OWB.Worksheets(1).cells(i1 + 2, NE + 10).value = i1
Next i1
'Se guardan los valores de los pesos obtenidos por la capa oculta y de
salida de la red neuronal.
For j = 1 To NO

```

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



```

        For i = 0 To NE
            OWB.Worksheets(2).cells(j, i + 1).value = W(j, i)
        Next i
        OWB.Worksheets(2).cells(j, i + 2).value = C(j)
    Next j
    OWB.Application.MaxChange = 0.001
    OWB.SaveAs("AprendizajeP1" & NO & "no" & alfa)
    OXL.Quit()
    OXL = Nothing
Next
Next
End Sub

Private Sub Button1_Click_1(ByVal sender As System.Object, ByVal e As
System.EventArgs) Handles Button1.Click
'Función para abrir el archivo que contiene las entradas de la red neuronal.
    Ruta = Application.StartupPath
    OXL = CreateObject("Excel.Application")
    OWB = OXL.Workbooks.Open(Ruta & "\EDEFNP52013")
    OXL.Visible = True
    Me.Activate()
End Sub

Private Sub Button3_Click(ByVal sender As System.Object, ByVal e As
System.EventArgs) Handles Button3.Click
'Función para cerrar el archivo con las entradas y el programa.
    Try
        OWB.Close(False)
        OXL = Nothing
        OXL.Quit()
        OXL = Nothing
    Catch ex As Exception
    End Try
    Application.Exit()
End Sub

Private Sub Button4_Click(ByVal sender As System.Object, ByVal e As
System.EventArgs) Handles Button4.Click
'Función encargada de la normalización de los datos.
    Dim max As Long
    Dim min As Long
    ND = Val(TextBox("Ingresar Número de Datos", , 51))
    NE = Val(TextBox("Ingresar el número de la entrada", , 1))
    max = Val(TextBox("Ingresar Número de maximo", , ))
    min = Val(TextBox("Ingresar Número de minimo", , ))

    ReDim X(ND + 1000, NE)
    ReDim yd(ND + 1000)
    For i = 1 To NE
        For k = 1 To ND

```

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

```

X(k, i) = (Val(OWB.Worksheets(1).cells(k + 2, 1 + i).value))
OWB.Worksheets(1).cells(k + 2, 1 + i).value = (X(k, i) - min) / (max
- min)

If OWB.Worksheets(1).cells(k + 2, 1 + i).value > 1 Then
    OWB.Worksheets(1).cells(k + 2, 1 + i).value = 1
End If
If OWB.Worksheets(1).cells(k + 2, 1 + i).value < 0 Then
    OWB.Worksheets(1).cells(k + 2, 1 + i).value = 0
End If
Next k
Next i
End Sub

```

```

Private Sub Button5_Click(ByVal sender As System.Object, ByVal e As
System.EventArgs) Handles Button5.Click

```

'Código de la red neuronal de aprendizaje y predicción.

'Se pide al usuario que ingrese el número de datos, entradas e iteraciones.

```

ND = Val(InputBox("Ingresar Número de Datos para aprendizaje", , 30))
NV = Val(InputBox("Ingresar Número de Datos para validacion", , 20))
NE = Val(InputBox("Ingresar el número de entradas", , 84))
NO = Val(InputBox("Ingresar el número de neuronas ocultas", , 50))
NIT = Val(InputBox("Número de Iteraciones", , 1000))
alfa = Val(InputBox("Factor de Aprendizaje", , 0.005))
ReDim X(ND + 1000, NE), W(NO, NE), S(NO), yr(ND + 1000)
ReDim C(NO), yd(ND + 1000)

Ruta = Application.StartupPath
OXL = CreateObject("Excel.Application")
OWB = OXL.Workbooks.Open(Ruta & "\EDEFNP52013")
OXL.Visible = True
Me.Activate()

```

'Se almacenan los valores de entrada de la red neuronal.

```

For k = 1 To ND + NV
    For i = 1 To NE
        X(k, i) = (Val(OWB.Worksheets(1).cells(k + 2, 1 + i).value))
    Next i
    yd(k) = (Val(OWB.Worksheets(1).cells(k + 2, NE + 3).value))
Next k

Randomize()

```

'Se pregunta por la condición del check box, si esta esta seleccionada se generan pesos aleatorios de lo contrario se toman los pesos almacenados en el archivo con las entradas.

```

If CheckBox3.Checked Then

```

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

```

For j = 1 To NO
    For i = 1 To NE
        W(j, i) = (Rnd()) / 100
    Next i
    C(j) = (Rnd()) / 100
Next j
Else
    For j = 1 To NO
        For i = 0 To NE
            W(j, i) = OWB.Worksheets(2).cells(j, i + 1).value
        Next i
        C(j) = OWB.Worksheets(2).cells(j, i + 2).value
    Next j
End If

```

'Se inicia el proceso de aprendizaje (Proceso Feedforward)

```

Dim ERS As Single
If ND <> 0 Then
    For i1 = 1 To NIT
        ERS = 0
        For k = 1 To ND
            yr(k) = 0
            For j = 1 To NO
                S(j) = 0
                For i = 1 To NE
                    S(j) = S(j) + X(k, i) * W(j, i)
                Next i
                yr(k) = yr(k) + C(j) * S(j)
            Next j

```

'Se implementan las funciones de activación.

```

If CheckBox1.Checked Then
    yr(k) = Math.Tanh(yr(k))
Else
    If CheckBox2.Checked Then
        yr(k) = 1 / (1 + Math.E ^ (-yr(k)))
    End If
End If
OWB.Worksheets(1).cells(k + 2, NE + 4).value = yr(k)
er1 = yd(k) - yr(k)
OWB.Worksheets(1).cells(k + 2, NE + 5).value = er1

ERS = ERS + Math.Pow(er1, 2)

```

'Se corrige el error por medio del uso de la regla del gradiente del error.

```

For j = 1 To NO
    If CheckBox1.Checked Then

```

```

C(j) = C(j) + alfa * er1 * S(j) * (2 / (Math.E ^ (C(j) *
S(j)) + Math.E ^ (-C(j) * S(j)))) ^ 2
Else
    If CheckBox2.Checked Then
        C(j) = C(j) + alfa * er1 * S(j) * Math.E ^ (-C(j) *
S(j)) / ((1 + Math.E ^ (-C(j) * S(j))) ^ 2)
    Else
        C(j) = C(j) + alfa * er1 * S(j)
    End If
End If

For i = 1 To NE
    If CheckBox1.Checked Then
        W(j, i) = W(j, i) + alfa * er1 * (C(j) * X(k, i) *
((2 / (Math.E ^ (C(j) * X(k, i) * W(j, i)) + Math.E ^ (-C(j) * X(k, i) * W(j, i))))
^ 2))
    Else
        If CheckBox2.Checked Then
            W(j, i) = W(j, i) + alfa * er1 * C(j) * X(k, i)
* Math.E ^ (-C(j) * W(j, i) * X(k, i)) / ((1 + Math.E ^ (-C(j) * W(j, i) * X(k, i)))
^ 2)
        Else
            W(j, i) = W(j, i) + (C(j) * er1) * alfa * X(k,
i)
        End If
    End If
Next i
Next j
Next k
'Se calcula el error en cada iteración.

ERS = Math.Sqrt(ERS / ND)
OWB.Worksheets(1).cells(i1 + 2, NE + 9).value = ERS
OWB.Worksheets(1).cells(i1 + 2, NE + 10).value = i1

Next i1
For j = 1 To NO
    For i = 0 To NE
        OWB.Worksheets(2).cells(j, i + 1).value = W(j, i)
    Next i
    OWB.Worksheets(2).cells(j, i + 2).value = C(j)
Next j
OWB.Application.MaxChange = 0.001
End If

ERSV = 0
For k = ND + 1 To ND + NV
    yr(k) = 0
    For j = 1 To NO
        S(j) = 0

```

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

```

        For i = 1 To NE
            S(j) = S(j) + X(k, i) * W(j, i)
        Next i
        yr(k) = yr(k) + C(j) * S(j)
    Next j
    If CheckBox1.Checked Then
        yr(k) = Math.Tanh(yr(k))
    Else
        If CheckBox2.Checked Then
            yr(k) = 1 / (1 + Math.E ^ (-yr(k)))
        End If
    End If
    OWB.Worksheets(1).cells(k + 2, NE + 4).value = yr(k)
    If k < (ND + NV - 4) Then
        er1 = yd(k) - yr(k)
        OWB.Worksheets(1).cells(k + 2, NE + 5).value = er1
        ERSV = ERSV + Math.Pow(er1, 2)
    End If
Next k
'Se calculan los valores RMSE.

ERSV = Math.Sqrt(ERSV / NV)
OWB.Worksheets(1).cells(ND + NV + 3, NE + 6).value = ERSV
OWB.Worksheets(1).cells(ND + NV + 3, NE + 7).value = i1

OWB.Application.MaxChange = 0.001
OWB.SaveAs("ValidacionP5" & NIT)
OXL.Quit()
OXL = Nothing

End Sub

Private Sub Button6_Click(ByVal sender As System.Object, ByVal e As
System.EventArgs) Handles Button6.Click
'Código para la creación del mapa de radiación.

ReDim XC(5), YC(5)
ReDim XBR(1000), YBR(1000), yr(ND)
ReDim hx(1000, 5), hy(1000, 5)
Dim RPx(), RP(), SRPx(), RPy(), SRPy(), YPred() As Double
Dim R(), YPr, n, Pix As Double
ReDim RPx(1000, 5), RP(5), SRPx(1000), RPy(1000, 5), SRPy(1000),
YPred(1000), R(5)

Pix = Val(TextBox("Ingrese el número de cuadrículas (max. val. 1000)", ,
100))

```

'Se definen las posiciones de los centros de las neuronas en X y en Y.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

```

XC(1) = 0.0 : XC(2) = 0.42265 : XC(3) = 0.75967 : XC(4) = 1.0 : XC(5) =
0.85083
YC(1) = 1.0 : YC(2) = 0.79675 : YC(3) = 0.61879 : YC(4) = 0.28094 : YC(5) =
0.0
R(1) = 0.42265 : R(2) = 0.33702 : R(3) = 0.33785 : R(4) = 0.28094 : R(5) =
0.28094

```

'Se dan valores de radiación a cada punto de medición a partir de los resultados de predicción.

```

RP(1) = 0.821383888
RP(2) = 0.98052208
RP(3) = 0.750964868
RP(4) = 0.751678547
RP(5) = 0.809600046

```

'Se crea el número de puntos a analizar.

```

n = 0
For i = 1 To Pix
    XBR(i) = n
    YBR(i) = n
    n = n + 1 / Pix
Next

Ruta = Application.StartupPath
OXL = CreateObject("Excel.Application")
OWB = OXL.Workbooks.Open(Ruta & "\Mapa")
OXL.Visible = True
Me.Activate()
'For k = 1 To 5 'N predicc
For i = 1 To Pix 'N Entradas
    SRPx(i) = 0 : SRPy(i) = 0 : YPred(i) = 0
    For j = 1 To 5 'N Puntos
        hx(i, j) = 0 : hy(i, j) = 0
        hx(i, j) = Math.E ^ ((-1 / 2) * (Math.Sqrt((XBR(i) - XC(j)) ^ 2)) /
R(j) ^ 2)
        hy(i, j) = Math.E ^ ((-1 / 2) * (Math.Sqrt((YBR(i) - YC(j)) ^ 2)) /
R(j) ^ 2)
        RPX(i, j) = hx(i, j) * 1 ' RP(j)
        RPY(i, j) = hy(i, j) * 1 ' RP(j)
        SRPx(i) = SRPx(i) + RPX(i, j) : SRPy(i) = SRPy(i) + RPY(i, j)
    Next j
Next i

```

'Se guardan los datos en una hoja de Excel para graficar la salida.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

```
For xi = 1 To Pix
    For yi = 1 To Pix
        YPr = SRPx(xi) * SRPy(yi)
        OWB.Worksheets(1).cells(Pix - yi + 1, xi).value() = YPr
    Next yi
Next xi
```

```
End Sub
End Class
```



## ESCUELA DE INGENIERÍA DE ANTIOQUIA

### ACTA DE EVALUACIÓN FINAL DE TRABAJO DE GRADO

Fecha: ( dd /mm / aa)	/11/ 2013
Nombre del Proyecto:	Modelo para la predicción de la Radiación Solar a partir de Redes Neuronales Artificiales
Nombre del Director:	Juan Alejandro Peña Palacio
Nombre del estudiante	Programa académico
Andrés Felipe González Rodríguez	Ingeniería Mecatrónica
Nombre del Jurado:	Carlos Velásquez Josa Palacio
Evaluación del proyecto: Espacio exclusivo para jurado	
<input type="checkbox"/> No aprobado <input checked="" type="checkbox"/> Aprobado sin mención	
<input type="checkbox"/> con Mención Pública <input type="checkbox"/> con Mención honorífica <input type="checkbox"/> Trabajo laureado	
Justificación del reconocimiento: (Artículo 28 del Acuerdo 11: "El director del Programa presentará el acta final de evaluación al Consejo Académico, donde consta la solicitud de mención especial debidamente justificada y el Consejo determinará si se otorga o no")	

DIRECTOR DEL PROGRAMA

DIRECTOR DEL TRABAJO DE GRADO

JURADO (Si lo hubo)

DIRECTOR DE PROGRAMA  
Jurado